

SVEUČILIŠTE U SPLITU
KEMIJSKO-TEHNOLOŠKI FAKULTET

MLADEN PERIŠIĆ

**MODELIRANJE POKAZATELJA ONEČIŠĆENJA
KOMUNALNE OTPADNE VODE GRADA SPLITA**

Doktorski rad

Split, prosinac 2012.

UNIVERSITY OF SPLIT
FACULTY OF CHEMISTRY AND TECHNOLOGY

MLADEN PERIŠIĆ

**MODELLING POLLUTION INDICATORS OF MUNICIPAL
WASTEWATER OF SPLIT**

Doctoral thesis

Split, December, 2012

Tema rada prihvaćena je na 11. sjednici Fakultetskog vijeća Kemijsko-tehnološkog fakulteta
u Splitu održanoj dana 24. svibnja 2012. godine.

Bibliografski podatci

UDK:	628.31“2006/2009“ (497.5 Split) (043.3)
Znanstveno područje:	Tehničke znanosti
Znanstveno polje:	Kemijsko inženjerstvo
Institucija u kojoj je rad izrađen:	Zavod za kemiju okoliša Kemijsko-tehnološkog fakulteta u Splitu
Mentori:	Dr. sc. Mirjana Čurlin, doc. Dr. sc. Marija Bralić, izv. prof.
Broj stranica:	126
Broj slika:	53
Broj tablica:	31
Broj priloga:	0
Broj literaturnih referenci:	88
Datum obrane:	28.01.2013.
Sastav povjerenstva za obranu:	
Dr. sc. Davor Rušić, red. prof.	Kemijsko-tehnološkog fakulteta u Splitu
Dr. sc. Maja Kliškić, red. prof.	Kemijsko-tehnološkog fakulteta u Splitu
Dr. sc. Pero Dabić, izv. prof.	Kemijsko-tehnološkog fakulteta u Splitu
Dr. sc. Marija Bralić, izv. prof.	Kemijsko-tehnološkog fakulteta u Splitu
Dr. sc. Mirjana Čurlin, doc.	Prehrambeno-biotehnološkog fakulteta u Zagrebu

Rad je pohranjen u:

knjižnici Kemijsko-tehnološkog fakulteta u Splitu, Teslina 10/V

Sveučilištu u Splitu, Livanjska 5

Sveučilišnoj knjižnici u Splitu, Zagrebačka 3

Nacionalnoj i sveučilišnoj knjižnici u Zagrebu, Hrvatske bratske zajednice 4

ZAHVALA

Završetak mog doktorskog rada bilo je jedno dugo putovanje. „Život je ono što ti se događa dok planiraš nešto drugo“ pjeva John Lennon u jednoj svojoj pjesmi. Izgrađujući ga, on nam daje dovoljno vremena da upravljamo s njim. Ovaj rad za mene predstavlja kraj jednog puta, jednog lijepog i intenzivnog razdoblja u mom životu, obilježenog mnogim dobrim ljudima te brojnim lijepim iskustvima. Stoga koristim ovu stranicu da se zahvalim osobama zbog kojih mi je svaki dan u protekle četiri godine predstavljao novi izazov.

Ponajprije od srca zahvaljujem se mentorici prof. dr. sc. Mirjani Čurlin na stručnom vodstvu i nesebičnoj pomoći tijekom izrade doktorske disertacije.

Veliko hvala i komentorici prof. dr. sc. Mariji Bralić na uloženom trudu tijekom osmišljavanja teme te stilskom oblikovanju ovog rada, dobronamjernim primjedbama i preporukama, a posebice na iskazanom strpljenju sve ove godine.

Zahvala i mr.sc. Ljubici Šimac-Peraica kao i svim djelatnicima Laboratorija za otpadne vode poduzeća Vodovod i kanalizacija u Splitu na pomoći pri izradi rada.

Zahvaljujem se i ostalim članovima povjerenstva, prof. dr. sc. Davoru Rušiću, prof. dr. sc. Maji Kliškić i prof. dr. sc. Peri Dabiću koji su izdvojili vremena i truda da podignu razinu kvalitete ovog rada.

Istinsko hvala i članovima Zavoda za kemiju okoliša na prijateljskoj suradnji te pruženoj stručnoj i tehničkoj pomoći.

Na kraju najveće hvala obitelji na strpljenju i podršci, na ljubavi i povjerenju koje su imali prema meni.

Mladen Perišić

SADRŽAJ

1.	UVOD	1
2.	OPĆI DIO	3
2.1.	Zaštita okoliša.....	3
2.1.1.	Zakonodavstvo zaštite okoliša.....	4
2.2.	Otpadne vode	5
2.2.1.	Značaj komunalnih voda i upravljanje njihovom kvalitetom	10
2.2.2.	Glavni pokazatelji sastava otpadne vode	14
2.2.3.	Vrste pročišćavanja otpadnih voda	17
2.2.3.1.	Prethodni stupanj pročišćavanja	18
2.2.3.2.	Prvi stupanj pročišćavanja	20
2.2.3.3.	Drugi stupanj pročišćavanja	21
2.2.3.4.	Treći stupanj pročišćavanja	22
2.2.4.	Aktivni mulj	23
2.2.5.	Membranski procesi	25
2.2.6.	Značaj projekta EKO - Kaštelanski zaljev	26
2.3.	Modeliranje kemijsko-tehnološkog procesa	31
2.3.1.	Fizičko modeliranje	31
2.3.1.	Matematičko modeliranje	32
2.4.	Statističke analize pokazatelja onečišćenja	32
2.4.1.	Multivarijantne metode	33
2.4.2.	Klaster analiza	34
2.4.3.	Analiza glavnih komponenata	35
2.4.4.	Faktorska analiza	38
2.4.5.	Višestruka regresija	39
2.4.6.	Nelinearni regresijski model	40
2.5.	Modeliranje postrojenja za obradu otpadne vode	41
2.5.1.	Modeliranje procesa obrade otpadne vode	43
2.5.1.1.	Nestrukturni modeli	43
2.5.1.2.	Empirijski modeli	45
2.6.	Neizrazita logika	47
3.	METODIKA	52
3.1.	Uzorkovanje otpadne vode	52

3.2.	Određivanje značajki otpadne vode	54
3.2.1.	Određivanje ukupnih suspendiranih čestica	54
3.2.2.	Određivanje kemijske potrošnje kisika	55
3.2.3.	Određivanje biokemijske potrošnje kisika	56
3.2.4.	Određivanje klorida	57
3.2.5.	Određivanje sulfata	58
3.2.6.	Određivanje orto-fosfata	58
3.2.7.	Određivanje amonijaka salicilatnom metodom	58
3.2.8.	Određivanje nitrita	59
3.2.9.	Određivanje nitrata uz 2,6-dimetilfenol	59
3.3.	Analiza rezultata mjerenja	60
3.3.1.	Osnovna statistička analiza pokazatelja onečišćenja komunalne otpadne vode grada Splita	60
3.3.2.	Multivarijantna analiza za prostornu i vremensku klasifikaciju pokazatelja onečišćenja	61
3.3.3.	Izrada multivarijabilnih linearnih modela	62
3.3.3.1.	Viševarijantni linearni model	63
3.3.3.2.	Model lokalne linearne regresije	64
3.3.4.	Određivanje indeksa kvalitete komunalnih otpadnih voda grada Splita primjenom neizrazite logike	66
4.	REZULTATI	71
4.1.	Osnovna statistička analiza pokazatelja onečišćenja komunalne otpadne vode grada Splita	71
4.2.	Prostorna i vremenska klasifikacija pokazatelja onečišćenja komunalnih otpadnih voda grada Splita	78
4.3.	Viševarijantni linearni model pokazatelja onečišćenja komunalnih otpadnih voda grada Splita	83
4.4.	Određivanje indeksa kvalitete komunalnih otpadnih voda grada Splita primjenom neizrazite logike	91
5.	RASPRAVA	106
5.1.	Osnovna statistička analiza pokazatelja onečišćenja komunalne otpadne vode grada Splita	107

5.2.	Prostorna i vremenska klasifikacija pokazatelja onečišćenja komunalnih otpadnih voda grada Splita	110
5.3.	Viševarijantni linearni model pokazatelja onečišćenja komunalnih otpadnih voda šireg područja grada Splita	113
5.3.1.	Viševarijantni linearni model (MLR)	113
5.3.2.	Model lokalne linearne regresije (PLR)	114
5.4.	Određivanje indeksa kvalitete komunalnih otpadnih voda grada Splita primjenom neizrazite logike	115
6.	ZAKLJUČCI	119
7.	LITERATURA	121

SAŽETAK

Upravljanje kvalitetom vode danas je najvažnija aktivnost zaštite okoliša. Indikatori kvalitete vode određuju se prema klasifikaciji, gdje je uzeta u obzir integracija parametara kvalitete vode i Pravilnika o kvaliteti vode.

U ovom radu provedena je karakterizacija i klasifikacija pokazatelja onečišćenja komunalne otpadne vode grada Splita na osnovi rezultata mjerenih parametara dobivenih svakodnevnim monitoringom na ispustima šireg područja kroz period od 4 godine. Temeljem dobivenih eksperimentalnih podataka provedena je osnovna statistička analiza određivanja srednjih vrijednosti, medijana, standardne devijacije, minimalnih i maksimalnih vrijednosti, te njihovih međusobnih korelacijskih koeficijenata. Dobivene su izrazito visoke koncentracije za kloride i sulfate kao i za ukupnu suspendiranu tvar te za kemijsku potrošnju kisika (KPK) koji nekoliko puta prelaze maksimalno dozvoljenu koncentraciju (MDK). Medijan vrijednosti bile su za sva onečišćenja niže od njihovih srednjih vrijednosti osim za biološku potrošnju kisika (BPK_5) i pH. Najviša vrijednost koeficijenta varijacije dobivena je za $N-NO_2$ na Lokacijama 2 i 3, a za deterđente na Lokaciji 1. Najmanji koeficijent varijacije zabilježen je za pH vrijednost na svim lokacijama. Provedena je prostorna i vremenska karakterizacija pokazatelja onečišćenja korištenjem različitih kemometrijskih tehnika (klaster analiza CA, faktorske analize FA, analize glavnih komponenata PCA). Prostorna klaster analiza pokazala je podjelu klastera u dvije grupe; klaster I formira Lokacija 2 i 3, a klaster II Lokacija 1. Prema vremenskoj klasifikaciji promatrano razdoblje moguće je podijeliti na razdoblje 2006.-2007. i razdoblje 2008.-2009. Provedene statističke analize poslužile su kao baza za dva linearna modela. Izrađeni su viševarijantni linearni model (MLR) i model lokalne linearne regresije (PLR) za predviđanje najznačajnijih pokazatelja onečišćenja KPK i BPK_5 s devet nezavisnih varijabli. Dobiveni regresijski koeficijenti viševarijantnog linearnog modela iznose $R^2 = 0,306 - 0,448$, dok regresijski koeficijenti za model lokalne linearne regresije iznose $R^2 = 0,534 - 0,683$.

Indeks kvalitete otpadne vode grada Splita određen je na temelju pravila neizrazite logike, koja predstavljaju kvalitetu vode putem jezičnih pojmova. Nakon primarne obrade, kvaliteta vode na Lokaciji 1 ocjenjena je kao „dobra“ sa stupnjem pripadnosti 0,476, dok za druge dvije lokacije prema stupnju pripadnosti (0,981 i 0,351) kvaliteta vode je ocjenjena kao „korektna“.

Ključne riječi: komunalna otpadna voda, pokazatelji onečišćenja, statistička analiza, klaster analiza, faktorska analiza, analiza glavnih komponentata, pravila neizrazite logike

SUMMARY

Water quality management is the most significant environmental activity today. Water quality indicators were estimated according to classification, where the integration of water quality parameters and Water Quality Regulations were taken into consideration.

In this paper, the quality of primary treated urban wastewater, discharged at three locations into the Adriatic Sea, is described based on the results of measured parameters obtained daily monitoring on drain locations wider Split area over a period of 4 years. Experimental data were analyzed by basic statistical methods for determination of mean and median values, standard deviations, minimal and maximal value of the measured parameters and their mutual correlation coefficients. The results obtained showed extremely high concentrations for chlorides, sulphates, total suspended solids and for chemical oxygen demand (COD) which several times exceed the maximum allowed concentration (MAC). Median values were lower for all pollutants from their mean values except biological oxygen demand (BOD₅) and pH. The highest value of the coefficient of variation was obtained for N-NO₂ at Locations 2 and 3, and for detergents at Location 1. The lowest coefficient of variation was recorded for pH value at all locations. Different chemometric techniques such as cluster analysis (CA), factor analysis (FA) and principal component analysis (PCA) were established to investigate spatial and temporal characterization of pollution indicators. Spatial cluster analysis showed the distribution of clusters in two groups; cluster I is formed by Locations 2 and 3 and cluster II is formed by Location 1. The observed time period can be divided in the period 2006-2007 and the period 2008-2009 according temporal classification. The statistical analyses were used as bases for two linear models. Multivariate linear regression model (MLR) and piecewise linear regression (PLR) were made to predict the most important pollution indicators COD and BOD₅ with 9 independent variables. The obtained regression coefficients for multivariate linear model amounts $R^2 = 0.306 - 0.448$, while regression coefficients for piecewise linear regression model amounts $R^2 = 0.534 - 0.683$.

Municipal wastewater quality index in the city of Split, based on the fuzzy set rules that represent water quality via linguistic terms. After primary treatment, water quality, at Location 1 was estimated as “good” with the highest degree of membership of 0.476, while at other two locations regarding to highest degrees of membership (0.981 and 0.351), water quality was estimated as “fair”.

Key words: municipal wastewater, pollution indicators, statistical analysis, cluster analysis, factor analysis, principal component analysis, fuzzy set rules

UVOD

U novije vrijeme, jedan od vodećih problema u svijetu postaje zagađenost okoliša, poglavito vodenih eko-sustava. Naime, tehnološki razvitak, praćen porastom broja populacije u urbanim sredinama i ljudskom nebrigom, a djelomično i neodgovornim ponašanjem rezultirao je sve većim onečišćenjem prirodnih recipijenata. U početku je voda u prirodi svojom autopurifikacijskom moći odolijevala sve većem zagađivanju, dok je u ljudskoj svijesti još uvijek bila prisutna spontana predodžba o neograničenoj moći samopročišćavanja čiji su se mehanizmi odvijali prema prirodnim zakonitostima. Danas se nalazimo u situaciji kada je kakvoća vodnih resursa narušena do te mjere da prirodni mehanizmi samopročišćavanja više ne mogu kompenzirati posljedice zagađenja kojima su vodeni tokovi svakodnevno izloženi.

Stoga je od osobite važnosti pronaći adekvatan način da se spriječe zagađenja, racionalizira potrošnja vode, te da se počne ulagati u preventivu i zaštitu vode od negativnih utjecaja, pri čemu će sve važniju ulogu imati postupci pročišćavanja otpadne vode prije ispuštanja u prirodne recipijente. U pogonima za pročišćavanje, svi kontaminanti iz otpadne vode moraju biti svedeni na prihvatljivo nisku razinu ili kemijski prevedeni u neškodljive komponente. Konačan izbor sustava koji će biti korišten za pročišćavanje ovisi o tipu i količini otpadne vode, kao i o ekonomskim, urbanističkim i ekološkim aspektima. Također, ovisno o kategoriji u koju je uvršten određeni recipijent, postoje norme koje definiraju *maksimalno dozvoljenu koncentraciju* (MDK) pojedine vrste onečišćenja. Sustavno praćenje vrijednosti pokazatelja onečišćenja može poslužiti i kao vrijedna spoznaja o kakvoći otpadne vode koja se ispušta u određeni recipijent, a statistička obrada dobivenih podataka kao i modeliranje procesa nužan je korak u svakoj preliminarnoj studiji koja ima za cilj optimiranje i/ili unapređenje vođenja procesa pročišćavanja otpadne vode.

U ovom radu provest će se karakterizacija pokazatelja onečišćenja otpadnih voda grada Splita na tri ispusta u periodu 4 godine. Provest će se statistička analiza mjerenih parametara (pokazatelja onečišćenja) koja će poslužiti kao baza za izradu dva linearna modela najznačajnijih pokazatelja onečišćenja (KPK i BPK₅) na sve tri lokacija za period od 4 godine. Izradit će se multivarijabilni linearni regresijski model (MLR) i model lokalne linearne regresije (PLR). S obzirom na nelinearnost sustava obrade otpadne vode osim ovih linearnih modela upotrijebit će se naprednija metoda modeliranja, metoda neizrazite (fuzzy) logike koja će poslužiti za postavljanje indeksa kakvoće otpadne vode na sve tri crpne stanice komunalne otpadne vode u Splitu.

Rezultati disertacije dobiveni znanstvenim pristupom problemu onečišćenja otpadnih voda i korištenjem naprednih programskih sustava za obradu, analizu i modeliranje sustava na različitim lokacijama imali bi veliki značaj u planiranju i projektiranju novih sustava za obradu otpadne vode na području Splitsko dalmatinske županije, posebice u ovom razdoblju pristupanja Hrvatske Europskoj uniji i što boljoj iskoristivosti sredstava iz pristupnih fondova.

Važnost istraživanja proizlazi iz činjenice da je Republika Hrvatska bogata izvorima pitke vode, ali ima nedovoljno suvremenih pogona za pročišćavanje otpadnih voda kako komunalnih tako i industrijskih. Period pristupanja EU potrebno je iskoristiti za usklađivanje zakona o kakvoći vode, snimanju stvarnog stanja na pojedinim lokacijama posebice u velikim urbanim sredinama kako bi se pravovaljano iskoristila novčana sredstva iz EU fondova s ciljem izgradnje pogona za pročišćavanje i zaštite okoliša.

Glavni znanstveni doprinos istraživanja je u analizi stanja na pojedinim komunalnim ispustima definiranju stvarnih pokazatelja onečišćenja kao i njihovih prosječnih vrijednosti za duži vremenski period. Dobiveni modeli omogućavaju predviđanje stanja na pojedinom sustavu preko najznačajnijih pokazatelja onečišćenja, KPK i BPK₅ vrijednosti koji su ključni za učinkovitost obrade. Naprednijim metodama modeliranja uporabom neizrazite logike moguće je indeks kakvoće vode na pojedinoj lokaciji opisati lingvističkim pravilima koja će pomoći stručnjacima različitih struka u boljem razumijevanju, a to će imati utjecaja na donošenje pravilne odluke o smještaju postrojenja kao i smjernicama za projektiranje novih sustava za pročišćavanje otpadnih voda na području Splitsko- dalmatinske županije.

2. OPĆI DIO

2.1. Zaštita okoliša

Kroz povijest ljudska aktivnost nije značajno utjecala na okoliš sve do razvoja industrije. Prve promjene koje je čovjek izazvao su nastale uslijed fizičke aktivnosti, fizioloških potreba. No razvojem i stvaranjem društvenih zajednica počinje nagli utjecaj na životni okoliš. Zaštita okoliša predstavlja skup odgovarajućih aktivnosti i mjera kojima je cilj sprječavanje onečišćenja i zagađenja okoliša, sprječavanje nastanka šteta, smanjivanje i/ili otklanjanje šteta nanesenih okolišu te povrat okoliša u stanje prije nastanka štete. Zaštitom okoliša osigurava se cjelovito očuvanje kakvoće okoliša, očuvanje biološke i krajobrazne raznolikosti, racionalno korištenje prirodnih dobara i energije.¹

Zaštita od onečišćenja i očuvanje pojedine sastavnice okoliša uređuju se Zakonom, posebnim zakonima, i propisima donesenim na temelju tih zakona a uključuju: zaštitu tla i zemljine kamene kore, zaštitu šumskog područja, zaštitu zraka, voda, mora i obalnog područja, zaštitu prirode, zaštitu od štetnog utjecaja genetski modificiranih organizama, zaštitu od buke, zaštitu od ionizirajućih zračenja i nuklearnu sigurnost, zaštitu od štetnog utjecaja kemikalija, od svjetlosnog onečišćenja te gospodarenje otpadom.

Zaštita voda od onečišćavanja provodi se radi očuvanja života i zdravlja ljudi te zaštite okoliša, te omogućavanja održivog, neškodljivog i neometanog korištenja voda za različite namjene. Zaštita mora obuhvaća mjere zaštite mora uključujući morski ekosustav i obalno područje kao nedjeljive cjeline, sprječavanje štetnih zahvata na morski ekosustav, sprječavanja onečišćenja mora iz zraka, s kopna, s plovila i drugih onečišćivača uslijed pomorskog prometa uključujući i onečišćenje prouzročeno odbacivanjem s brodova ili iz zrakoplova sa svrhom potapanja ili spaljivanjem na moru, te prekograničnog onečišćenja, kao i sprječavanje onečišćenja uslijed velikih nesreća i uklanjanje njihovih posljedica. Gospodarenje otpadom obuhvaća mjere za sprječavanje nastanka i smanjivanje količina otpada, bez uporabe postupaka i/ili načina koji predstavljaju rizik po okoliš, te mjere za sprječavanje štetnog djelovanja otpada na ljudsko zdravlje i okoliš.²

2.1.1. Zakonodavstvo zaštite okoliša

Kroz politiku zaštite okoliša države članice Europske unije zajednički provode mjere za zaštitu i poboljšanje kakvoće zraka, zaštitu voda, zaštitu prirodnih staništa i u njima nastanjenih biljnih i životinjskih vrsta. Poduzimaju aktivnosti koje pridonose boljem gospodarenju otpadom te djelotvornijoj kontroli industrijskog onečišćenja, kemikalija i genetski modificiranih organizama.³

Hrvatsko zakonodavstvo zaštite okoliša čine međunarodni ugovori (konvencije i protokoli) koje je potvrdio Hrvatski sabor, zakon i njihovi provedbeni procesi. Krovni zakon je Zakon o zaštiti okoliša.⁴ On osigurava podlogu za donošenje provedbenih akata kojima će se zakonodavstvo uskladiti s europskim, radi čega su u njega uvedeni novi pojmovi iz pravne stečevine Europske unije.

Ovim se Zakonom uređuje zaštita okoliša, a usklađivanjem i odgovarajućom provedbom propisa iz područja zaštite okoliša, Hrvatska osigurava visoke ekološke standarde, čime doprinosi zaštiti zdravlja svojih građana. Zakonom o zaštiti okoliša osigurava se cjelovito očuvanje kakvoće okoliša, očuvanje prirodnih zajednica, racionalno korištenje prirodnih izvora i energije na najpovoljniji način za okoliš, kao osnovni uvjet zdravog i održivog razvoja.

Zaštita okoliša je postala i važan zadatak za institucije Europske zajednice što se vidi najviše nakon Ugovora iz Maastrichta (1992.) za Europsku uniju ratificiranog od strane svih država članica. Možemo reći da je Europska unija vrlo aktivna na polju politike zaštite okoliša, što se vidi iz načina na koji djeluje, o procjeni štetnih čimbenika, odnosno njihovih utjecaja na okoliš do informiranja građana.

U postupku usklađivanja zakonodavstva, zaštita okoliša jedno je od najopsežnijih i najzahtjevnijih područja što i pokazuje podatak da je do danas doneseno oko 300 pravnih dokumenata iz ovog područja.⁵

Horizontalno zakonodavstvo čine direktive koje reguliraju zaštitu okoliša i srodna područja. One su više proceduralne nego tehničke. Propisuju postupke i mehanizme za integriranje skrbi za okoliš u odluke koje se donose u javnom i privatnom sektoru, vezane osobito za korištenje zemljišta i upravljanje prirodnim dobrima.⁵

1973. godine, na razini EU se usvaja prvi Akcijski plan zaštite okoliša. Aktualni Akcijski plan zaštite okoliša (6th Environmental Action Programme 2001-2010) predlaže pet prioritarnih oblasti strateške akcije:⁶

- usavršavanje implementacije postojeće zakonske regulative u ovoj oblasti,
- uključivanje politika zaštite okoliša u ostale politike,
- bliska suradnja s tržištem u ovim pitanjima,
- osnaživanje ljudi kao građana pojedinaca da promjene svoje ponašanje u skladu s ekološkim vrijednostima,
- uzimanje u obzir zaštitu okoliša pri planiranju upotrebe zemljišta.

Kao što se može vidjeti, jedino izvaninstitucionalno preporučeno područje je edukacija građana o važnosti zaštite okoliša u cilju izmjene njihovog ponašanja u pravcu usvajanja ekološke vrijednosti i ekološki odgovornog djelovanja. Ipak, bez ovih pretpostavki na razini pojedinca, vjerojatno je da primjena institucionalnih mehanizama neće dati očekivane rezultate. Suvremeno društvo mora brže i bolje shvatiti upozorenje znanstvenika i stručnjaka o stanju okoliša, tj. činjenice da slobodnog, izvornog i nezagađenog okoliša ima sve manje, a ugroženog i devastiranog sve više. Ekološka svijest predstavlja dio šire filozofije društvenog pokreta usmjerenog na očuvanje i unaprjeđenje prirodnog okruženja, kako u interesu pojedinca, tako i u interesu civilizacije i njenog opstanka u cjelini.⁷

2.2. Otpadne vode

Više od 70 % površine Zemlje prekriveno je vodom, no nažalost najveći dio te vode nije raspoloživ za piće. Naime, 97,5% vode je slano, a od preostalih 2,5% veći dio je smrznut na polovima. Tek oko 0,26% ukupne vode na Zemlji je pitka voda, a i taj mali dio pitke vode izložen je raznim vidovima zagađenja.⁸ Prema procjeni UNESCO-a više od 25 milijuna ljudi godišnje umire od bolesti uzrokovanih nedostatkom vode, lošom kvalitetom ili zagađenjem vode. Zbog toga će u vremenu koje dolazi voda biti najvažnija strateška sirovina. Istraživači Međunarodnog instituta za upravljanje vodama predviđaju potpunu nestašicu vode za dvadesetak godina u 17 zemalja svijeta.⁹

Voda ima posebna fizikalna i kemijska svojstva koja ju čine važnim biološkim i ekološkim čimbenikom živog svijeta na Zemlji, no voda ima i vrlo veliku gospodarsku važnost. Iz njezine biološke, ekološke i gospodarske važnosti proistječe i potreba, odnosno nužnost njene zaštite.

Razvoj naselja i povećanje standarda stanovništva uvjetuju zagađenje čovjekove okoline, a među najteže oblike zagađenja svakako ubrajamo i zagađenje voda. Potrošnja vode za razne potrebe postaje sve veća što uzrokuje i porast količina otpadnih voda.

Voda se u procesu kruženja može zagađiti u bilo kojoj fazi, a izvori zagađenja jesu tvorničke otpadne vode, zagađenja naftom i naftnim derivatima, kemikalije iz domaćinstava, kemikalije iz poljoprivrede (pesticidi, insekticidi, umjetna gnojiva i slično), vode iz septičkih jama i kanalizacije, javna smetlišta, kisele kiše itd. Ta zagađenja ne pogađaju samo nadzemne vode, već i podzemne rezervoare i izvore vode iz kojih najčešće crpimo vodu za piće. Tvari koje se nalaze u vodi u otopljenom stanju ne možemo okom vidjeti pa ih najčešće nismo ni svjesni, no voda itekako plaća danak razvitku industrije, urbanizacije i poljoprivrede. Dokaz za to u Hrvatskoj jesu brojna vodocrpilišta koja su morala biti isključena iz vodoopskrbnih sustava zbog onečišćenja. Premda je ispuštanje otpadnih voda posljednja operacija upravljanja sustavom odvodnje, uvjeti za njegovu provedbu imaju povratne posljedice na potrebni stupanj pročišćavanja otpadnih voda, i prema tome nikako se ne mogu odvojiti od ovog problema. Istodobno s ispuštanjem otpadnih voda treba kontrolirati stanje vodnih sustava u koje se ove vode ispuštaju, kako bi se spriječile sve neželjene promjene u ekosustavu. Poremećaji koji nastaju u ekološkim sustavima zbog ispuštanja otpadnih tvari su dugotrajniji i s višegodišnjim zakašnjenjem pojavljivanja njihovog utjecaja na okoliš. U Hrvatskoj se danas pročišćava nedovoljna količina ukupnih otpadnih voda. Mnogi gradovi u Hrvatskoj nemaju riješen problem pročišćavanja otpadnih voda što predstavlja opasan izvor zagađenja jer nepročišćene otpadne vode mogu dospjeti u podzemlje ili vodotokove te zagađiti izvorišta ili vodocrpilišta. Također, u Hrvatskoj nije riješen problem odlaganja komunalnog otpada na adekvatan način, što predstavlja veliku opasnost jer oborinske vode otapaju mnoge potencijalno opasne tvari koje postoje na deponijama otpada. Nakon što se otope u vodi one nastavljaju put u podzemlje te predstavljaju izuzetnu opasnost za izvorišta i vodocrpilišta.¹⁰

Pročišćavanjem otpadnih voda uklanjaju se neželjeni elementi iz vode, a mulj je neizbježan nusprodukt-otpad u pročišćavanju otpadnih voda. Pročišćena otpadna voda se ispušta u prirodni prijemnik, dok problem predstavlja izdvojeni mulj kojeg je potrebno dodatno obraditi i konačno zbrinuti radi očuvanja okoliša, kao i zdravstvenih i estetskih čimbenika.

Prema Strategiji upravljanja vodama: u Hrvatskoj postoji 108 uređaja za pročišćavanje otpadnih voda, od čega 96 većih od 500 ekvivalent stanovnika (ES). Ukupni instalirani kapacitet je 3.801.310 ES, od čega se 1.200.000 ES (32%) odnosi na uređaj grada Zagreba.¹⁰ Djelatnost odvodnje otpadnih voda čine poslovi skupljanja otpadnih voda, njihova

dovođenja do uređaja za pročišćavanje, pročišćavanja i ispuštanja u prijemnik, obrade mulja i poslovi odvodnje oborinskih voda iz naselja putem sustava javne odvodnje.

Priključenost na kanalizacijski sustav u Hrvatskoj iznosi više od 44 %. U prosjeku je to oko 70% u velikim gradovima, a ispod 40 % u naseljima s manje od 10.000 stanovnika.

Od ukupno 1.267 naselja koja imaju više od 500 stanovnika, njih 295 ima izgrađen sustav javne odvodnje, dok 972 naselja nema izgrađen sustav javne odvodnje, kao i većina od 5.387 naselja koja imaju manje od 500 stanovnika. Priključenost stanovništva na uređaje za pročišćavanje komunalnih otpadnih voda je u porastu. Samo 25% komunalnih otpadnih voda u Hrvatskoj se pročišćava. Uglavnom se kao prvi provodi mehanički stupanj pročišćavanja komunalnih otpadnih voda kojim se uklanja najmanji postotak onečišćujućih tvari. Izgrađeno je 57 uređaja s drugim stupnjem pročišćavanja, a pročišćavanje otpadnih voda trećeg stupnja, nažalost samo jedan uređaj.¹¹

Situacija s pročišćavanjem otpadnih voda još je zabrinjavajuća, jer je takvim sustavima obuhvaćen manji broj stanovništva Hrvatske, a cilj kojem će Republika Hrvatska težiti do 2015. godine je postizanje 65% priključenosti na sustav javne odvodnje, odnosno 41% priključenosti stanovništva na sustav pročišćavanja otpadnih voda. Priključenost stanovništva po županijama na sustav javne odvodnje prikazan je u tablici 1.¹²

Tablica 1. Priključenost stanovništva po županijama na sustave javne odvodnje

ŽUPANIJA	Broj stanovnika	Površina km ²	Gustoća naseljenosti	Priključenost stan. 2004 (%)	Priključenost stan. 2007 (%)	Priključenost stan. 2011 (%)	Priključenost stan. 2007	Dodatno priključ. stan. 2008-2011	Broj priklj. stanov.
ZAGREBAČKA	309.696	3.060	101,2	31%	32%	37%	98.182	15.300	113.482
KRAPINSKO-ZAGORSKA	142.432	1.230	115,8	11%	12%	15%	16.718	4.800	21.518
SISAČKO-MOSLAVAČKA	185.387	4.463	41,5	40%	40%	44%	73.998	7.700	81.698
KARLOVAČKA	141.787	3.620	39,1	30%	30%	36%	42.197	11.600	53.797
VARAŽDINSKA	184.769	1.260	146,5	20%	20%	26%	37.310	11.000	53.787
KOPRIVNIČKO-KRIŽEVAČKA	124.467	1.746	71,2	17%	18%	24%	22.836	7.500	30.336
BJELOVARSKO-BILOGORSKA	133.084	2.637	50,4	29%	29%	32%	37.933	5.200	43.133
PRIMORSKO-GORANSKA	305.505	3.558	85,1	53%	55%	59%	168.000	13.200	181.200
LIČKO-SENJSKA	53.6777	5.350	10,0	21%	24%	29%	12.688	2.700	15.388
VIROVITIČKO-PODRAVSKA	93.389	2.021	46,2	20%	20%	41%	18.569	19.800	38.369
POŽEŠKO-SLAVONSKA	85.831	1.820	47,1	41%	47%	49%	40.095	1.900	41.995
ZADARSKA	162.045	3.646	44,4	36%	39%	47%	63.917	12.930	76.848
OSJEČKO-BARANJSKA	330.506	4.148	79,6	41%	42%	51%	137.319	30.800	168.119
ŠIBENSKO-KNINSKA	112.891	2.987	37,8	30%	31%	42%	34.930	13.000	47.950
VUKOVARSKO-SRIJEMSKA	204.768	2.447	83,6	30%	30%	47%	61.463	34.950	96.413
SPLITSKO-DALMATINSKA	463.676	4.525	102,4	46%	52%	57%	242.968	22.700	265.668
ISTARSKA	206.344	2.815	73,3	54%	54%	58%	112.447	6.900	119.347
DUBROVAČKO-NERETVANSKA	122.870	1.780	69,0	27%	32%	42%	39.032	12.600	51.632
MEĐIMURSKA	118.426	729	162,4	12%	16%	31%	18.680	18.500	37.180
GRAD ZAGREB	779.145	640	1217,4	74%	74%	78%	577.811	30.000	607.811
UKUPNO	4.437.460	56.538	78,5	42%	44%	50%	1.935.022	286.380	2.212.670

Najmanja priključenost je u Krapinsko-zagorskoj županiji (37%), a najveća priključenost u Gradu Zagrebu (78%).

Dakle, voda koja nastaje nakon uporabe u domaćinstvima i industriji zove se otpadna voda i dijeli se na dvije velike skupine:⁷

Komunalne ili fekalne otpadne vode nastaju na sanitarnim čvorovima stambenih, javnih, industrijskih i drugih objekata gdje žive i rade ljudi, koji u fiziološkom procesu proizvode zagađenja u tekućem i čvrstom obliku.

Industrijske otpadne vode nastaju u tvornicama i industrijskim pogonima nakon upotrebe vode u procesu proizvodnje, kao i prilikom pranja aparata, uređaja i dr.

Postoje i vode koje se uvjetno mogu nazvati otpadnim vodama, a one uključuju:

- Oborinske ili atmosferske vode koje nastaju kao površinski proizvod od padavina i otopljenog snijega s urbanog područja. U ove vode se ubrajaju i otpadne vode od pranja uličnih površina, kolnika i dr.
- Rashladne vode su vode koje se koriste u industriji za hlađenje postrojenja odnosno za odvodnju viška topline.
- Infiltracijske vode su podzemne vode koje dotiču u kanalizacijsku mrežu preko cijevnih spojeva, drenažnih sustava i sl.

Obzirom da se otpadne vode sve češće pojavljuju kao miješane vode grada i industrije, njihovo ionako složeno pročišćavanje je još više otežano i zahtijeva primjenu različitih postupaka obrade.

Otpadne vode podrijetlom iz urbanog područja sadrže velike količine onečišćenja organskog i anorganskog podrijetla, što zahtijeva njihovu obradu i pročišćavanje prije ispuštanja u okoliš. Oborinske i rashladne vode ne sadrže značajnu količinu onečišćenja pa se mogu izravno ispuštati u vodene tokove. Onečišćivači prisutni u otpadnoj vodi mogu izazvati različite popratne pojave (tablica 2).¹³

Tablica 2. Fizikalna, kemijska i mikrobiološka analiza otpadnih voda

OTPADNE VODE			
Fizikalna analiza	Temperatura	Mutnoća	Radioaktivnost
	Boja	pH vrijednost	Gustoća
Kemijska analiza	Ostatak nakon isparavanja	Ostatak nakon žarenja	Toksičnost
	Miris	Elektrovodljivost	Taložive tvari
	Ukupni dušik	Ukupna tvrdoća	Šećer i škrob
	KPK	Ulja i masti	SO ₄ ²⁻ , SO ₃ ²⁻ , S ²⁻ , Mn ²⁺ , K ⁺ , Na ⁺
Bakteriološka analiza	BPK ₅	Fenoli	Deterdžent
		Kao i kod pitkih voda	

2.2.1. Značaj komunalnih otpadnih voda i upravljanje njihovom kvalitetom

Upravljanje vodama predstavlja jedno od prioritetnih pitanja u vezi s okolišem za razne institucionalne razine. Povijesno gledano, politika voda zasniva se na rješenjima za krajnje korisnike, na obradi otpadnih voda kako bi se smanjila količina onečišćenja koja se ispušta u prirodne recipijente. Danas, u 21. stoljeću, presudno područje interesa predstavlja holistički pristup upravljanju vodnim resursima. Vodna politika bavi se aspektima kakvoće i količine voda, budući da se niz zemalja suočava s raznim problemima u upravljanju vodama.¹⁴

U zadnjih nekoliko desetljeća, rastu problemi s okolišem i zato je naglašena maksimalna dnevna kontrola onečišćenja koja je potpuno promijenila orijentaciju u analizi sustava upravljanja kvalitetom vode. Problem vezan uz kvalitetu vode u priobalnim područjima je rastući problem zbog porasta zagađenosti u ovim područjima što može imati ozbiljne posljedice na okoliš. Nadalje, posebno treba istaknuti važnost kvalitete komunalne otpadne vode koja se ispušta u more.

Sustav gradskih otpadnih voda je sastavljen od tri glavne komponente: kanalizacijski sustav, postrojenje za pročišćavanje otpadnih voda i prihvatnih voda. Većina kanalizacijskih sustava su kombinirani kanalizacijski sustavi, što znači da oni prikupljaju otpadne vode, ali također mogu prihvatiti oborinsko otjecanje iz obližnjeg drenažnog područja (sliva).

Oborinsko otjecanje doprinosi stvaranju problema, posebice za vrijeme vlažnih vremenskih uvjeta, kod postrojenja za pročišćavanje otpadnih voda i u samom kanalizacijskom sustavu.

U korist upravljanja kvalitetom otpadnih voda ide i *Direktiva EU o „Sakupljanju, pročišćavanju i ispuštanju komunalnih voda“* usvojena 1991. godine, a u cilju zaštite okoliša od štetnog djelovanja gradskog ispusta otpadnih voda i ispuštanje iz industrijskog sektora. Iako ova Direktiva stvara velike materijalne troškove lokalnim jedinicama, ona označava pomak ka donošenju strogih normi i zakona koji imaju za cilj reguliranje kvalitete vode.

Kako bi se odredila kvaliteta otpadne vode koriste se neki kemijski parametri.

U Republici Hrvatskoj parametri za određivanje kvalitete voda propisani su *Pravilnikom o graničnim vrijednostima opasnih i drugih tvari u otpadnim vodama* (tablica 3).¹³

Tablica 3. Referentne vrijednosti prema Pravilnicima EK i RH za određene kemijske parametre

Pokazatelji mjerne jedinice	Referentne vrijednosti prema Pravilniku EK	Referentne vrijednosti prema vodopravnoj dozvoli RH
pH	6,5-9,5	6,5-9,5
Suspendirane Tvari	60 mg/l	35-150 mg/l
Biokemijska potrošnja kisika BPK ₅	40 mg O ₂ /l	40-250 mg/l
Kemijska potrošnja kisika KPK	125 mg O ₂ /l	125-700 mg/l
Ukupni fosfor	2 mg P/l	1-10 mg/l
Ukupni dušik	10 -15 mg N/l	10-15 mg/l

Prepoznati parametri koji se koriste pri definiranju kvalitete komunalnih voda su sljedeći: *pH*, *biološka potrošnja kisika (BPK₅)*, *kemijska potrošnja kisika (KPK)*, *ukupni dušik (N)*, *ukupni fosfor (P)* i *suspendirana tvar*. Opće odredbe ovog Pravilnika kažu da otpadne vode sustava javne odvodnje ili komunalne vode su sanitarne otpadne vode ili mješavina sanitarnih

otpadnih voda s tehnološkim otpadnim vodama i/ili oborinskim vodama određene aglomeracije.

Prethodno pročišćavanje znači obradu tehnoloških otpadnih voda u skladu sa zahtjevima za ispuštanje tehnoloških otpadnih voda u sustavu javne odvodnje. Pročišćavanje otpadnih voda je proces uklanjanja otpadnih tvari koji obuhvaća nekoliko stupnjeva pročišćavanja kojima se smanjuje koncentracija parametara za određivanje kvalitete otpadnih voda.

Kvaliteta komunalnih otpadnih voda ovisi o načinu življenja, klimatskim uvjetima, te sustavu opskrbe i odvodnje. U njihov sastav ulaze različiti organski i anorganski onečišćivači. Organski onečišćivači najčešće uključuju: masti, ulja, deterdžente, proteine, šećere, škrob, celulozu, ostatke hrane i dr., dok su anorganska onečistila: soli, mulj, pijesak, blato, razne suspendirane i koloidne tvari. Osim sastava komunalne otpadne vode, važan čimbenik za definiranje njezinih osnovnih karakteristika je i dnevna količina otpadne vode izražena kao protok. Prosječan sastav komunalne otpadne vode prikazan je tablicom 4.¹³


Tablica 4. Prosječan sastav komunalne otpadne vode

Parametar	Koncentracija, mg/L	
	opseg	prosječno
Ukupna suha tvar	300-1200	700
Suspendirane tvari, ukupno	100-400	220
Otopljene tvari	250-850	500
BPK ₅	100-400	250
KPK	200-1000	500
Ukupni dušik	15-90	40
Ukupni fosfor	5-20	12
pH - vrijednost	7-7,5	7,0
Kloridi, Cl	30-85	50

Prilikom dnevnog monitoringa količine i sastava komunalne otpadne vode, uočena su pravilna kolebanja i to s maksimalnim vrijednostima koje se pojavljuju kasno ujutro i rano navečer, dok su u ranim jutarnjim satima kad je potrošnja vode najmanja i ove vrijednosti najniže (slika 1). Komunalna otpadna voda pripada skupini srednje onečišćenih otpadnih voda i po ekvivalentu stanovnika iznosi $Q = 200 \text{ L/d}$.¹⁵


Promatrajući područje grada Splita ta vrijednost iznosi 180 L/d, ako se ne uzima u obzir koeficijent umanjenja od 0,95, što je važan podatak za računanje očekivanih koncentracija pokazatelja onečišćenja u komunalnim otpadnim vodama.¹⁶

Određivanje varijacija u količini otpadne vode (protocima), praćeno promjenama KPK i BPK₅ vrijednosti iznimno je važno prilikom projektiranja uređaja za obradu otpadnih voda što se može vidjeti na slici 1.¹⁵



Slika 1. Prikaz tipičnih satnih varijacija protoka i onečišćenja komunalne otpadne vode, gdje je BPK izražena kao koncentracija (g/m^3) i kao organsko opterećenje (kg/h)

Ako bi se potrošnja kisika prikazala kumulativnom krivuljom u funkciji temperature, dobio bi se dijagram poput onog na slici 2.¹⁷



Slika 2. Dijagram BPKs za tri različite temperature vode (1 prva faza, 2 druga faza)

2.2.2. Glavni pokazatelji sastava otpadne vode

Onečišćenje vode uzrokuju:¹⁷

a) **Krupni otpaci** su papir, krpe, kore od voća i ostali krupniji organski i sintetski otpaci.

Za razgradnju krupnih organskih otpadaka se troši kisik, pa se tako smanjuje količina otopljenog kisika u vodi.

b) **Raspršene i otopljene tvari** koje se nalaze u otopljenim vodama su tvari organskog i anorganskog porijekla. Raspršene tvari su krupnije čestice od otopljenih tvari koje se u otpadnim vodama nalaze u obliku iona i molekula. Prijelaz između raspršenih i otopljenih tvari čine koloidi. Otopljene i raspršene tvari uzrokuju promjenu boje u vodi, a raspršene tvari i koloidi tvore mutnoću. Povećana mutnoća vode sprječava prodiranje svjetlosti, što usporava *fotosintezu*. Zbog toga se u većim dubinama smanjuje količina kisika, pa se povećava zona anaerobne razgradnje organske tvari, čime se stvaraju plinovi neugodna mirisa.

c) **Mikroorganizmi** su jednostanični i višestanični organizmi koji se nalaze u svim otpadnim vodama. Za procese pročišćavanja otpadnih voda od naročitog su značenja slijedeće dvije skupine mikroorganizama:

- mikroorganizmi razlagači (saprofagni mikroorganizmi) i
- mikroorganizmi iz probavnog trakta ljudi i životinja (fekalni mikroorganizmi).

d) **Hranjive tvari** nastaju procesom razgradnje organske tvari iz otpadnih voda ispuštenih u prirodne i umjetne prijemnike. Ovaj proces je prvenstveno vezan uz nastanak soli dušika i

fosfora, koje sudjeluju u stvaranju bjelančevina i time potiču razvoj *planktona* i zelenih biljaka.

e) Postojane tvari su organske i sintetske biološki nerazgradive ili teško (sporo) razgradive tvari. I u razdoblju dok traje njihova eventualna razgradnja nepovoljno djeluju na akvatički život, a mogu se i nakupljati u organizmima. Od ovih su tvari u otpadnim vodama od prvenstvenog interesa *mineralna ulja, pesticidi, deterdženti i plastične tvari*.

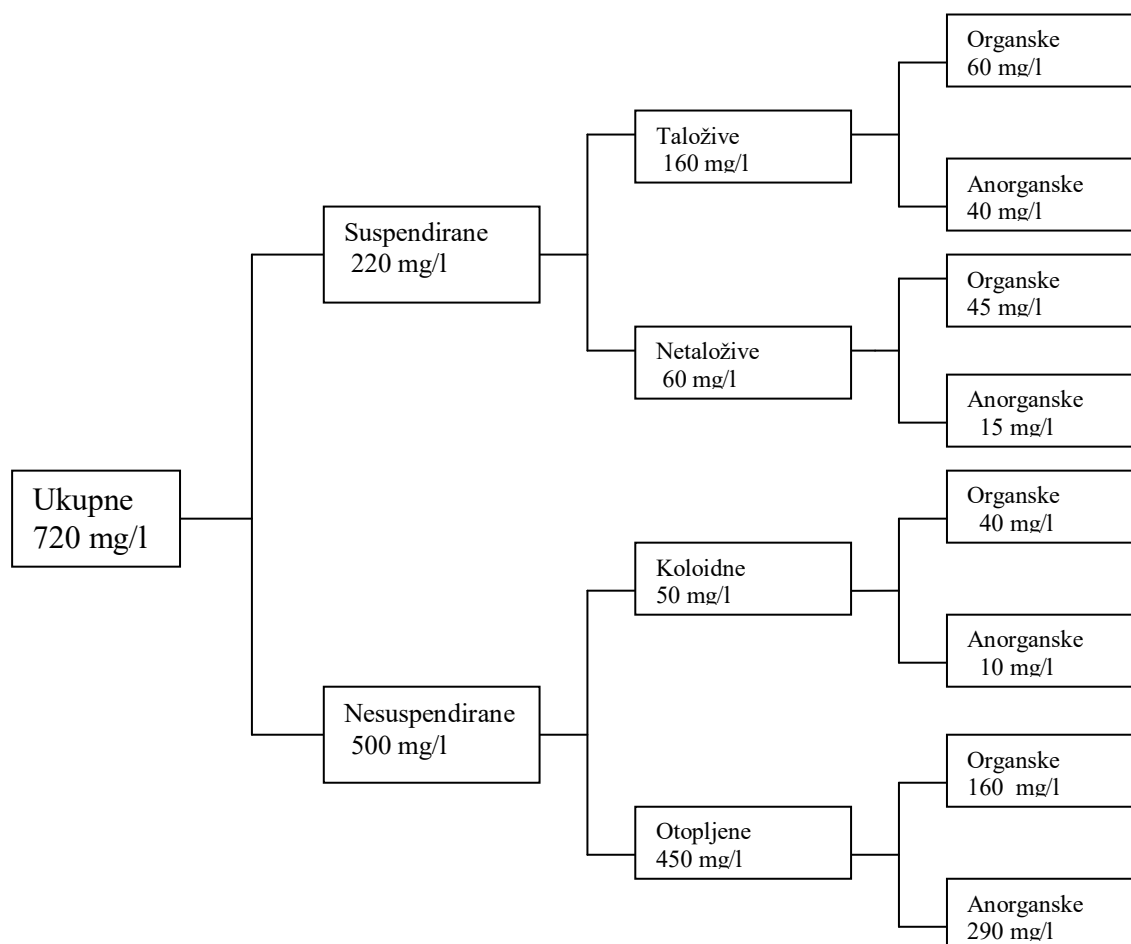
f) Otrovne tvari su tvari koje prema svojim količinama i svojstvima uzrokuju bolesti živih organizama, nenormalno ponašanje, kancerogene i genetičke promjene, fiziološke smetnje, fizičke deformacije i smrt. U otpadnim vodama opasne tvari dolaze u obliku *teških metala* (živa, kadmij, olovo, nikal, cink, srebro, mangan, krom, bakar, željezo) i *otrovnih spojeva* (cijanidi, kromati, fluoridi).

g) Radioaktivne tvari mogu u vodi biti prirodnog i umjetnog porijekla. *Prirodni izvori* zračenja su radioaktivni elementi litosfere i svemirska zračenja. *Umjetni izvori* zračenja su radioaktivne tvari koje se nalaze u industrijskim otpadnim vodama, prvenstveno vodama nuklearnih elektrana, a potom i vodama iz industrijskih pogona u kojima se koriste radionukleidi.

h) Otopljeni plinovi su u otpadnim vodama prisutni u različitim koncentracijama. Među najvažnijima je kisik koji je bitan za život velikog broja organizama u vodi. Nalazi se otopljen u vodoopskrbnoj vodi i tako dospijeva u otpadne vode. Pored kisika otpadne vode vrlo često sadrže ugljični dioksid, koji dolazi otapanjem iz zraka i razgradnjom organske tvari, te sumporovodik, koji prvenstveno nastaje razgradnjom organskih i nekih anorganskih spojeva.

i) Povišena temperatura vode posljedica je ispuštanja rashladnih voda iz industrijskih postrojenja, posebice termoelektrana i nuklearnih elektrana.

Sadržaj ukupne tvari u komunalnoj vodi prosječnog sastava može se približno prikazati kao na slici 3.¹⁵



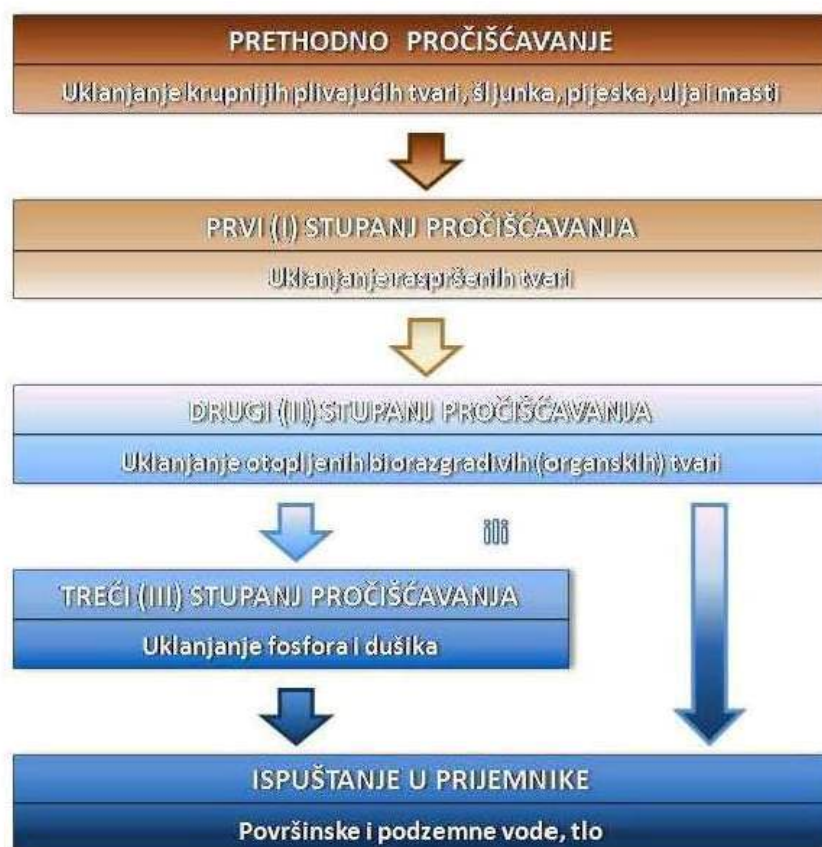
Slika 3. Prosječan sastav ukupne tvari u komunalnoj otpadnoj vodi

Temperatura otpadne vode je važan pokazatelj kakvoće otpadne vode za provedbu bioloških procesa jer o njoj ovisi koncentracija otopljenog kisika u vodi što izravno utječe na rast mikroorganizama. Naime, pri višim temperaturama koncentracija otopljenog kisika je smanjena. Uobičajena temperatura za provedbu aerobnih bioloških procesa iznosi 25-30 °C. Stoga se temperatura kao čimbenik mora motriti kako kod otpadne vode u sustavu za obradu, tako i kod obrađene vode prije ispuštanja u vodene sustave¹⁸.

2.2.3. Vrste pročišćavanja otpadnih voda

Pročišćavanje otpadnih voda obavlja se primjenom *fizikalnih, bioloških i kemijskih* postupaka ili procesa, tako da je s obzirom na primijenjene postupke i procese (slika 4.)¹² sukladno *Pravilniku o graničnim vrijednostima emisija otpadnih voda*, uobičajeno razlikovati:

- a) prethodno pročišćavanje (*preliminarno pročišćavanje*),
- b) prvi stupanj (I) pročišćavanja (*primarno pročišćavanje*),
- c) drugi stupanj (II) pročišćavanja (*sekundarno pročišćavanje*),
- d) treći stupanj (III) pročišćavanja (*tercijarno pročišćavanje*).



Slika 4. Vrste pročišćavanja otpadnih voda

2.2.3.1. Prethodni stupanj pročišćavanja

Postupci koji se primjenjuju kod ovog stupnja pročišćavanja kojeg još nazivamo i *mehaničko pročišćavanje* pretežno se temelje na fizikalnim pojavama i zakonitostima. Postupci prethodnog stupnja pročišćavanja se provode radi poboljšanja kvalitete otpadnih voda (prvenstveno smanjenja krupne otpadne tvari, šljunka, pijeska, masnoća) kao bi se uklonile one tvari koje mogu oštetiti dijelove uređaja za više stupnjeve pročišćavanja. Ovi postupci najčešće obuhvaćaju:

- rešetanje i/ili usitnjavanje,
- taloženje (u pjeskolovu) i isplivavanje,
- izjednačivanje (egalizaciju).

Razvoj rešetki za separaciju sitnijih čestica otvorio je nova polja u procesu obrade otpadne vode, pa korištenje rešetki čiji je razmak rešetke (engl. bar spacing) manji od 6 mm danas predstavlja trend u svijetu. Jedan od razloga jest taj što se efikasnost danas sve raširenijih membranskih procesa primjenom membranskih bioreaktora znatno povećava upravo zbog povećanja pouzdanosti izdvajanja vlaknastih materijala na ovakvim rešetkama. Redukcija vlakana u primarnom mulju rezultira poboljšanom konzistencijom pa se mulj i lakše pumpa.¹⁸

Daljnja primjena navedenih uređaja moguća je u obradi otpadne vode prije neposrednog ispuštanja u rijeku i more, obzirom da se na ispustima najčešće provodi samo standardna mehanička obrada. Stoga je sve izraženija potreba za rešetkama poboljšanih karakteristika i sve očitija važnost smanjenja omjera KPK/BPK₅ u otpadnoj vodi koja se ispušta u prirodne vodotoke.

Spomenute moderne rešetke u sklopu jednog procesnog stupnja mogu ukloniti nerazgradive tvari kao što su plastični materijali i pamučne zamjene, zajedno sa organskim komponentama sadržanim u otpadnoj vodi. Na ovaj način, tj. primjenom novih tehnologija ostvaruje se visok stupanj zaštite okoliša uz smanjene troškove kao što je prikazano na slici 5.¹⁹



Slika 5. *Prikaz grube rešetke HUBER CLIMBMAX® koja se postavlja u kanale ispred uređaja za obradu otpadnih voda u svrhu zaštite finih rešetki i drugih pogonskih elemenata od krupnijih onečišćenja*

Daljnje poboljšanje efikasnosti ovih rešetki može se postići dodatkom tvari za precipitaciju i koagulaciju koje izazivaju efekt pretvorbe otopljenih sitnih čestica sadržanih u otpadnoj vodi u čestice koje se mogu izdvojiti. Ovaj efekt ima za posljedicu smanjenje koncentracije ukupne suspendirane tvari za čak 95%, omjera KPK/BPK₅ za 65% i koncentracije fosfata za 60% (slika 6)¹⁹



Slika 6. *Prikaz fine rešetke HUBER ROTAMAT® Fine Screen Ro1 kao polifunkcionalne zasebne jedinice u procesu obrade otpadne vode – izdvajanje, pranje, sabijanje i transport materijala*

Stoga, za mnoga područja u svijetu u kojima ne postoji obrada otpadne vode ili ona nije na adekvatnoj razini, uporaba finih rešetki može predstavljati prvi i brzi korak u pravom smjeru.

Efikasnost finih rešetki očituje se kroz slijedeće pokazatelje:²⁰

- *uklanjanje čestica sadržanih u otpadnoj vodi ima za posljedicu redukciju BPK₅ za 10-20% i KPK za 10-30%,*
- *mehanička obrada nema značajnog utjecaja na otopljene tvari u otpadnoj vodi, tj. na oko 2/3 organskog opterećenja, BPK₅ i KPK se ne može djelovati,*
- *svaki protok otpadne vode se može podvrgnuti procesu obrade koristeći odvojene uređaje paralelno postavljene.*

2.2.3.2. Prvi stupanj pročišćavanja

Ovaj postupak nazivamo *biološko pročišćavanje* jer se iz prethodno pročišćenih otpadnih voda prvenstveno uklanjaju taložive suspendirane tvari, uz dodatni efekt istodobnog smanjenja BPK₅.²¹

Ovi se postupci temelje na fizikalno - kemijskim procesima koji u općem slučaju obuhvaćaju:

- a) koagulaciju i flokulaciju,
- b) taloženje (u prethodnim ili primarnim taložnicima) i isplivavanje.

Taloženje je obvezatan postupak prvog stupnja pročišćavanja, dok ostali postupci (sukladno svojstvima otpadnih voda) doprinose bržem i efikasnijem taloženju, odnosno pročišćavanju. Općenito, kod biološkog pročišćavanja otpadnih voda razlikujemo dva stupnja taloženja.²²

- taloženje u prethodnim taložnicima, iz kojih se voda nakon prvog odvodi na drugi stupanj pročišćavanja, tj. na biološke procese,
- taloženje u naknadnim taložnicima, u koje se dovodi voda pročišćena biološkim procesima u sklopu drugog stupnja pročišćavanja.

Taloženje u prethodnim taložnicima se primjenjuje za uklanjanje suspenzija koje se u otpadnim vodama nalaze u obliku zrna i pahuljica. Učinak pročišćavanja otpadnih voda u prethodnim taložnicima može se prikazati kao:

- smanjenje BPK₅ za 25 do 40%,
- smanjenje ukupnih raspršenih tvari za 40 do 70%,

- smnjenje bakterija za 25 do 75%,
- smnjenje KPK za 20 do 35%.

2.2.3.3. Drugi stupanj pročišćavanja

U načelu, kod drugog stupnja pročišćavanja uobičajeni su biološki postupci koji mogu biti nadopunjeni i nekim fizikalno – kemijskim procesima.

Generalno, drugi stupanj pročišćavanja obuhvaća:²³

- a) biološke procese (npr. u aeriranim spremnicima s aktivnim muljem, lagunama, prokapnicima, okretnim biološkim nosačima, anaeorbnim digestorima),
- b) taloženje (u naknadnim ili sekundarnim taložnicima) i isplivavanje,
- c) dezinfekciju.

Drugim stupnjem pročišćavanja najčešće su obuhvaćene prva i druga skupina postupaka, dok se dezinfekcija primjenjuje samo u posebnim slučajevima kada se želi smanjiti broj patogenih mikroorganizama.

Biološki procesi se primarno primjenjuju za pročišćavanje kućanskih otpadnih voda i industrijskih otpadnih voda s pretežnim udjelom organske (biološki razgradive) tvari i sa sadržajem opasnih tvari ispod kritičnih koncentracija. Pročišćavanje biološkim procesima temelji se na aktivnosti mikroorganizama koji razgrađuju mrtvu organsku tvar upotrebljavajući je kao hranu za gradnju novih stanica (umnožavanje). Uz razvoj mikroorganizama kao produkt bioloških procesa nastaju plinovi i nerazgradivi ostatak. Prema količini otopljenog kisika u otpadnoj vodi i prema prilikama u staništu mogući su sljedeći procesi:

- aerobna gradnja i razgradnja stanica,
- anaerobno kiselo vrenje i metanska razgradnja,
- bakteriološka oksidacija i redukcija.

Aerobni procesi nastaju kada u vodi ima dovoljna količina otopljenog kisika. Kisik se troši prilikom razgradnje raspršene i koloidne organske tvari koju mikroorganizmi upotrebljavaju kao hranu. Istodobno mikroorganizmi razgrađuju vlastite stanice uz ponovnu potrošnju kisika.

Aerobnim postupcima se proizvodi višak žive i mrtve organske i anorganske tvari koji se naziva *viškom mulja*.²⁴

Anaerobni procesi nastaju kad u vodi nema otopljenog kisika. Ovaj proces se odvija u dvije faze. U prvoj (kiseljoj) fazi bakterije kiselog vrenja razgrađuju organsku tvar do organskih kiselina koje su hrana za metanske bakterije u drugoj fazi razgradnje. Prilikom anaerobnih procesa nastaje mnogo manje novih stanica (mikroorganizama) nego tijekom aerobnih.

Bakteriološka oksidacija i redukcija omogućuje oksidaciju željeza, mangana i sumpornih spojeva te redukciju i oksidaciju dušikovih spojeva.

Aerirani spremnici s aktivnim muljem se izvode kao bazeni u koje se uvodi otpadna voda i upuhuje zrak ili kisik uz istodobno miješanje sadržaja spremnika, čime se ubrzava dodir pahuljica hranjivih tvari i mikroorganizama.²⁵

2.2.3.4. Treći stupanj pročišćavanja

Treći stupanj pročišćavanja otpadnih voda primjenjuje se samo u slučajevima kada je nužan vrlo visok stupanj pročišćavanja, odnosno kada je iz otpadnih voda potrebno ukloniti neke osebujne tvari (npr. otopljene soli, mikroorganizme, pesticide, deterdžente, otrovne i radioaktivne tvari i sl.).


Kod komunalnih otpadnih voda ovaj stupanj pročišćavanja se najčešće primjenjuje za uklanjanje hranjivih tvari (dušika i fosfora) nakon provedenog drugog stupnja, kako bi se u vodoprijemniku spriječio proces eutrofikacije.

Ovaj postupak je baziran na:²⁶

- a) fizikalnim procesima (filtraciji, adsorpciji, membranskim procesima), kojima se iz vode uklanjaju mutnoća, miris, boja, otopljene soli te mikroorganizmi,
- b) kemijskim procesima (neutralizaciji, kemijskom obaranju ili kemijskoj precipitaciji, ionskoj izmjeni, oksidaciji i redukciji, dezinfekciji) kojima se iz vode uklanjaju otopljene tvari, teški metali, mikroorganizmi, mijenja pH vrijednost te provodi pretvorba nekih opasnih spojeva u manje opasne,
- c) biološki procesima (uklanjanju dušika i fosfora), kojima se uklanjaju dušikovi i fosfori spojevi.

Biološkom razgradnjom pomoću mikroorganizama organski spojevi koji sadrže dušik prelaze u amonijak, NH_3 , koji potom u prvoj fazi oksidira u nitrite, NO_2^- , a u drugoj fazi u nitrate, NO_3^- . Ovaj proces nazivamo *nitrifikacija*.^{27,28}

Sumarna reakcija:



Biološkom razgradnjom nitrati se (uz dodavanje ugljikovih spojeva i bez kisika) reduciraju u plinoviti dušik, N_2 , koji odlazi u atmosferu, što nazivamo *denitrifikacija*.^{29,30}


Sumarna reakcija:



2.2.4. Aktivni mulj

Tehnologija obrade otpadne vode aktivnim muljem danas je najzastupljenija u obradi otpadnih voda, te je to jedan od najraširenijih postupaka obrade otpadne vode. Iako pored velike ekonomičnosti i učinkovitosti postupka biološke obrade otpadne vode, postoje i određene nepogodnosti. Naime, uspješnost biološke obrade otpadne vode ovisi o biološkoj aktivnosti mikro populacije, te je nužno nadziranom radom sustava poticati rast i aktivnost mikroorganizama.³¹

Aktivnim muljem nazivamo masu mikroorganizama raspršenih u spremniku koji u aerobnim prilikama mogu razgraditi organsku tvar. Međusobno povezivanje potpomažu polisaharidi koje izlučuju pojedine vrste mikroorganizama. Mješovitu mikrobnu zajednicu aktivnog mulja čine bakterije, kvasci, alge, protozoe, metazoe (rotifere, nematode). Točan sastav mješovite kulture, odnosno udjeli pojedinih vrsta mikroorganizama ovise o kemijskom sastavu otpadne vode, uvjetima okoline, fazama samog procesa, kao i o specifičnim karakteristikama organizama koji se nalaze u toj zajednici. Zastupljenost pojedinih vrsta organizama u aktivnom mulju je prikazana slikom 7.³¹



Slika 7. Relativni omjer zastupljenosti pojedinih vrsta mikroorganizama tijekom rasta u flokuli aktivnog mulja

U aktivnom mulju svaka vrsta organizama svojom aktivnošću doprinosi učinkovitosti uklanjanja sastojaka iz otpadne vode. Najveću biokemijsku aktivnost imaju bakterije zbog brzog rasta i raznolikog enzimskog potencijala za razgradnju sastojaka različitih kemijskih struktura u otpadnoj vodi i zbog toga su najbrojnija vrsta.³²

Učinak bioaeracijskih bazena ovisi o opterećenju aktivnim muljem. Za otpadne vode s malim udjelom industrijskih voda ($BPK_5 = 150$ do 350 mg/l) postiže se smanjenje organske tvari od 75 do 95%. Manja vrijednost se odnosi na zimsko razdoblje ($T < 11$ °C), a veća za ljetno razdoblje ($T > 13$ °C).³¹

Upuhivanje zraka ili kisika u spremnike s aktivnim muljem i miješanje otpadnih voda moguće je postići *dubinskom i površinskom aeracijom*. Iz aeriranih spremnika s aktivnim muljem otpadna voda se s mješavinom otpadnih tvari i mikroorganizama dovodi u *naknadni taložnik*. Odatle se dio aktivnog mulja vraća u bioaeracijski bazen kako bi se povećala koncentracija mikroorganizama, a ostatak se odvodi na obradu mulja.^{33,34}

Da bi se pospješilo povezivanje mikroorganizama u pahuljice aktivnog mulja dodaju se različiti inertni materijali kao nosači mikroorganizama. Najčešće se upotrebljava aktivni ugljen, čestice poliuretana, keramika i dr.

Proces obrade otpadne vode aktivnim muljem je složen, dinamički, nelinearni proces koji ima dosta prednosti, ali i nedostataka. Jedna od prednosti ovog postupka je proizvodnja visoke kvalitete efluenta za razuman operativni proces. Također prednost se

očituje i u lakšem rukovanju procesom obrade, izostanku mirisa te nižem prinosu mulja. Nedostaci procesa se vide u većoj potrošnji energije, nemogućnosti obrade toksičnog dijela otpada kao i težem prilagođavanju ciklusa obrade u manjim lokalnim jedinicama.³⁵

Visoki stupanj kontrole aktivnog mulja je uspješno primijenjen kod inteligentnog sustava kontrole postupaka za obradu otpadne vode.³⁶

2.2.5. Membranski procesi

Sukladno novim i strogim zakonskim zahtjevima za višom kakvoćom obrađene otpadne vode razvijene su membranske tehnologije, biološke metode obrade otpadne vode uporabom *membranskog bioreaktora* (MBR).³⁷

MBR je tehnologija koja pripada grupi separacijskih procesa s biološkom obradom s aktivnim muljem. Mehanička predobrada otpadnih voda prilagođena je zahtjevima bioloških procesa koji se odvijaju unutar bioreaktora. Proračuni jedinice za obradu voda izrađeni su za određen broj reaktora uređaja uzevši u obzir karakteristične oscilacije količina i kakvoće dotoka na uređaj, a kako bi parametri efluenta na izlazu iz uređaja uvijek bili u granicama zadanih.

Potrebno je istaknuti veliku prednost membranskih procesa nad ostalim procesima obrade otpadne vode, obzirom da ne upotrebljavaju kemikalije, na malom prostoru mogu obraditi velike količine vode, uz manju količinu istaložene biomase aktivnog mulja, a dobivena voda je visoke kakvoće. U membranskom uređaju se ulazna voda protiskuje kroz poroznu membranu djelovanjem povišenog tlaka čime se razdvaja u dvije struje. Jedna struja je permeat ili filtrat u kojem se prolazom kroz membranu smanjuje koncentracija otopljenih tvari, te koncentrat ili retentant koji ne prolazi kroz membranu i u njemu se koncentracija otopljenih tvari povećava.³⁸

Zahvaljujući kombinaciji klasične bioobrade s aktivnim muljem i separacijskoj – membranskoj tehnologiji, dobila se procesna konfiguracija koja je jednostavna glede procesa i održavanja, isplativa, fleksibilna i isplativa.

Sustav je primjenjiv za obradu gradske otpadne vode, a i za djelomičnu ili potpunu obradu raznih industrijskih otpadnih voda. Unutar reaktorske sekcije postoji zona za denitrifikaciju, a u aeracijskom dijelu putem jednostavne kontrole aeracije efikasno se uklanjaju nutrienti dušik i fosfor.^{39,40}

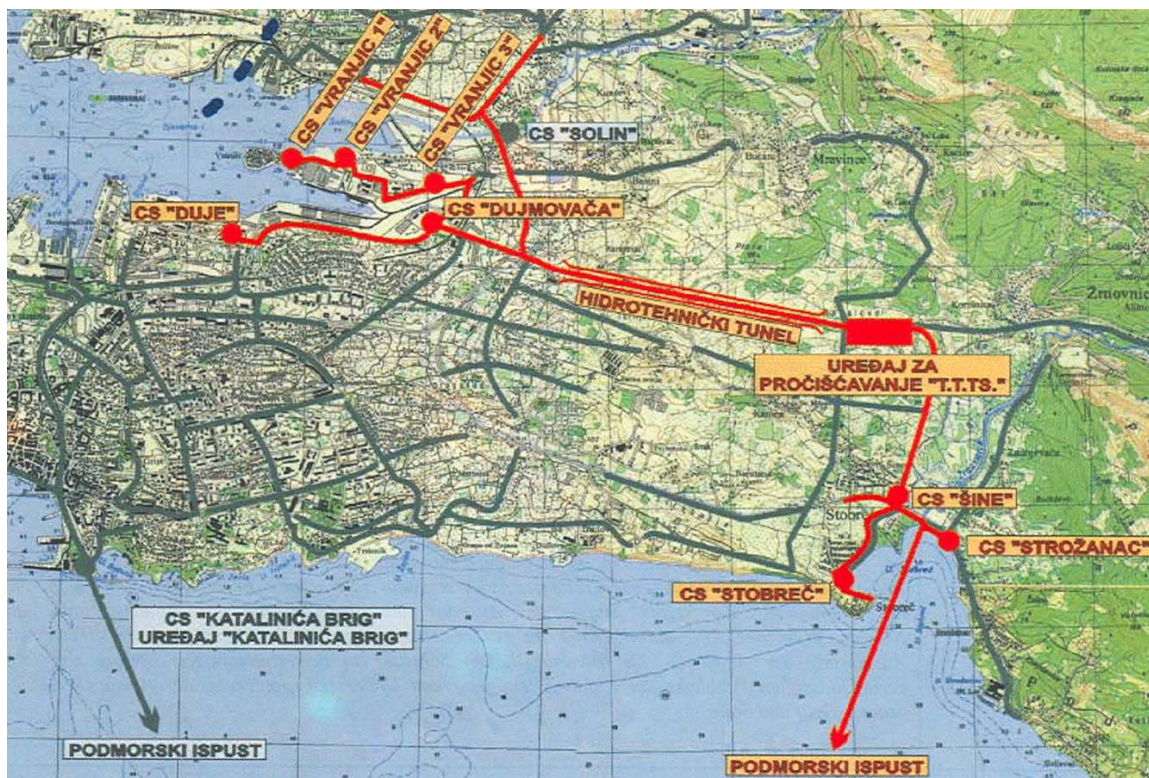
U posljednje vrijeme troškovi energije za pogon uređaja kao i troškovi nabave membrana su smanjeni za oko 80%. Daljnjim usavršavanjem mogu se očekivati još niži troškovi.

2.2.6. Značaj projekta EKO - Kaštelanski zaljev

Gradovi Split i Solin u ovome trenutku čine veliki iskorak prema trajnom rješavanju dugo zanemarivanog problema odvodnje i pročišćavanja gradskih otpadnih voda, koji se javio kao posljedica stihijskog i nekontroliranog razvoja u nekoliko posljednjih desetljeća.

Projekt EKO – Kaštelanski zaljev podrazumijeva rekonstrukciju kanalizacijske mreže te poboljšanje i dogradnju vodoopskrbnog sustava. Obuhvaća izgradnju objekata za prikupljanje, pročišćavanje i disponiranje otpadnih voda u sklopu kanalizacijskih sustava (kolektorska mreža, cjevovodi, crpne stanice, uređaj za pročišćavanje otpadnih voda, podmorski prijelaz, hidrotehnički tunel, podmorski ispust) i izgradnju objekata za poboljšanje sustava vodoopskrbe (crpne stanice, vodospreme, tlačne i gravitacijske kolektore). Sustavi su kapacitirani za do 411.000 ES.⁴¹

Dugoročno rješenje kanalizacijskog sustava područja Splita i Solina riješeno je izgradnjom centraliziranoga kanalizacijskog sustava, sa središnjim uređajem za pročišćavanje otpadnih voda (CUPOV) *Stupe* i pripadajućim ispustom u Stobreču. Kanalizacijski sustav Grada Splita dijeli se na dva velika sliva, Južni i Sjeverni sliv, a oba su mješovitog tipa kako je i prikazano na slici 8.⁴²




Slika 8. Generalni koncept rješenja izgradnje kanalizacijskog sustava Split/Solin

Izgradnjom kanalizacijskog sustava EKO Kaštelanski zaljev izvršeni su zahvati na kolektorima Sjevernog sliva, te se otpadne vode prepumpavaju do hidrotehničkog tunela, a potom gravitacijom dolaze do Uređaja Stupe. Nakon odvajanja pijeska, masti i ulja, ispuštaju se preko Ozračnog okna u Brački kanal. Ovaj sustav je kapacitiran za 250.000 ES što je dostatno za idućih 30 godina. Objekti *Kanalizacijskog sustava Split-Solin* su: Hidrotehnički tunel Stupe, Uređaj za pročišćavanje otpadnih voda Stupe, Podmorski ispust Stobreč, Kanalizacijska područja Vranjica, Mreža slivova Dujmovača-Solin, Objekti dodatne mreže, Hidromehanička oprema, Sustav daljinskog nadzora i upravljanja. Svi objekti su završeni i za sve objekte je izvršena primopredaja krajnjem korisniku Vodovodu i kanalizaciji d.o.o. Split. Kaštelanski zaljev, a posebno najugroženiji istočni dio, se izgradnjom ovog sustava oporavio tako da više nema cvjetanja mora, pomora ribe i sličnih pojava. Radi zaštite slivnog područja i izvorišta rijeke Jadro, ali i optimizacije cjelokupnog sustava gradi se kanalizacija područja Klis-Dugopolje. Projekt optimalizacije na području Splita obuhvaća i Podsustav Spinut-Poljud, koji će se priključiti na postojeći Kanalizacijski sustav Split i uređaj Katalinića brig. Ostali objekti koji se grade u sklopu optimalizacije cjelokupnog sustava su: kanalizacija

Uvale Baluni, kanalizacija zapadnog dijela grada Solina (Sv. Kajo) i dio kanalizacijske mreže Žrnovnice.⁴¹

Izgradnjom Kanalizacijskog sustava Split-Solin i Stobrečka uvala ima bolju kvalitetu mora što se vidi praćenjem rada Podmorskog ispusta, odnosno utjecaja istog na okoliš. Prema zadnjim rezultatima istraživanja koje je proveo splitski Institut za oceanografiju i ribarstvo u sklopu programa „*Praćenje utjecaja podmorskog ispusta Stobreč na okoliš*“, koncentracije indikatora fekalnog zagađenja su tijekom 2010. godine gotovo na čitavom istraživačkom području bile vrlo niske, a kakvoća mora izvrsna. Ovi rezultati upućuju na značajno poboljšanje sanitarne kakvoće mora u priobalnom području nakon puštanja u rad podmorskog ispusta.⁴³

S obzirom da podaci *monitoringa* kakvoće komunalnih voda u Splitu pokazuju visok stupanj razrijeđenosti i procese samopročišćavanja za transport kanalizacijskim sustavom, procjena tereta zagađenja u otpadnim vodama domaćinstava i turizma izvršena je (radi sigurnosti) na temelju parametara srednjeg dnevnog opterećenja otpadnom tvari: $BPK_5 = 60 \text{ mg/st.dan}$, $KPK = 120 \text{ mg/st.dan}$, ukupne suspenzije $= 70 \text{ mg/st.dan}$.⁴⁴ Rezultati procjene tereta zagađenja za dva planska razdoblja prikazani su na slici 9.⁴⁵




Slika 9. Procijenjeni teret zagađenja na uređaju za pročišćavanje za dva planska razdoblja (2010. i 2025.) te usporedba s veličinama iz Projekta

Dakle, ukupni teret zagađenja na uređaju za pročišćavanje odgovara opterećenju od 135.000 ES-a u 2010. godini te 360.000 ES-a u 2025. godini.


U tehnološkom smislu, projektno rješenje uređaja za pročišćavanje u prvoj etapi izgradnje i u konačnom stanju izgrađenosti bazirano je na zaključcima studije izvedivosti koja je utvrdila da na lokaciji Stupe postoji dovoljno prostora za razvijanje svih poznatih tehnologija II. stupnja pročišćavanja, uključivo i onih prostorno najzahtjevnijih.

Zakonska kategorija „odgovarajućeg stupnja pročišćavanja“, pretpostavljena je u prvoj fazi izgradnje uređaja *Stupe* kategoriji „potrebnog stupnja pročišćavanja“. Ovakav stav ni u kojem slučaju ne isključuje kategoriju potrebnog (konačnog) stupnja pročišćavanja, kojeg je potrebno izgraditi tek onda kada se ispune svi tehničko-tehnološki uvjeti i obave

istraživačke predradnje koje osiguravaju njegovu punu efikasnost. U međuvremenu se niža razina pročišćavanja kompenzira odgovarajućim načinom ispuštanja, kojim se (u skladu s propisima) u sanitarnom smislu čuva obalni pojas širine 300 m, a moru u okolici difuzora prepušta da svojim autopurifikacijskim sposobnostima odigra ulogu prirodnog pročišćivača, čija „imitacija“ na uređaju rezultira novim utjecajima na okoliš (mulj). Imajući sve na umu, shema prethodnog pročišćavanja s grubim (10 mm), i finim (2 mm) rešetkama/sitima i aeriranim pjeskolovom (mastolovom) (slika 10.) može se smatrati optimalnom za prvu etapu izgradnje, budući da sigurno zadovoljava uvjete sprječavanja pojave vidljivog zagađenja u moru, omogućava realno uklanjanje suspendiranih tvari u rasponu od 15-25%, te je ujedno i najneutralnija u odnosu na hidrauličke parametre i oscilacije kakvoće sirove otpadne vode.⁴⁵



(a) presjek kroz kanal s rešetkom (10 mm) i finom rešetkom-sitom (2 mm)



(b) presjek kroz aerirani pjeskolov-mastolov

Slika 10. Prva etapa razvoja CUPOV-a Stupe – uređaj s prethodnim stupnjem pročišćavanja

2.3. Modeliranje kemijsko-tehnološkog procesa

Kod suvremenih procesa kemijske tehnologije koji se izvode velikim brzinama, na visokim temperaturama i tlakovima i u višefaznim sustavima, kao osnovno obilježje se može postaviti velika složenost. Ta složenost se iskazuje mnoštvom raznovrsnih parametara, koji određuju tok procesa, zatim brojnim unutarnjim vezama među parametrima, te njihovom međuzavisnošću. Uz to još među parametrima postoje i brojne petlje povratnih veza, kao i pojava suprotnog djelovanja procesa. Pored toga je veoma velik i vanjski broj (potencijal) informacija o kemijsko-tehnološkim procesima. Taj broj treba smanjiti i ograničiti količinu mogućnosti između kojih se provodi izbor. To se postiže upoznavanjem procesa pomoću modela takvih sustava koji izražavaju pojedinačna ograničenja i gledišta pojava promatranog procesa.⁴⁶

Kod toga postoje dva stadija:

1. kod kojeg se model uspoređuje s pojavom i smatra se da zadovoljava ako razlike nisu velike,
2. kod kojeg se uspoređuje očekivana pretpostavka s prikazanim modelom

Taj postupak se naziva *modeliranje*. Razlikuju se dva načina modeliranja:

- a) fizičko,
- b) matematičko.

2.3.1. Fizičko modeliranje

Pri fizičkom modeliranju proučavanje određene pojave se provodi njenim prikazivanjem u različitim dimenzijama i analizom fizičkih svojstava i linearnih omjera. Eksperiment se izvodi neposredno na proučavanom fizičkom procesu. Eksperimentalno dobiveni rezultati obrađuju se predočeni u obliku zavisnosti bezdimenzijskih grupa (značajki), sastavljenih kombiniranjem različitih fizičkih veličina i linearnih dimenzija. Takav bezdimenzijski oblik (značajka) omogućuje primjenu dobivenih zavisnosti na skupinu međusobno sličnih pojava za koje je značajna konstantnost dobivenih bezdimenzijskih značajki ili kriterija sličnosti.


Tako se fizičko modeliranje svodi na predočavanje nepromjenjivosti istraživanih kriterija sličnosti na modelu i objektu. Praktički to znači da je istraživani fizički proces potrebno prikazivati u nekoliko stadija, tj. prelaziti od manjih dimenzija njegova prikaza ka većim, mijenjajući prema nekoj zakonitosti njegove linearne dimenzije (princip sličnosti).

Na taj se način deformacija fizičkog modela izvodi neposredno na samom objektu u kojem se zbiva proces. Taj pristup zahtjeva prikazivanje procesa u sve većim dimenzijama, sve do tvorničkih i vrlo složenih sustava kakvi se susreću u kemijskoj tehnologiji.⁴⁶

2.3.2. Matematičko modeliranje

Kod matematičkog modeliranja model procesa se ne proučava na fizičkom modelu (kao kod fizičkog modeliranja), već neposredno na samom matematičkom modelu pomoću elektroničkih računala.⁴⁶

Matematičko modeliranje uključuje sljedeće postupke:



Dinamičko modeliranje procesa se temelji na teorijskoj analizi istraživnog sustava.

2.4. Statističke analize pokazatelja onečišćenja

Ekolozi trebaju posebno biti zainteresirani za statistiku, ne zbog njene istinske elegancije, nego zbog toga što im ona pruža alate koje mogu upotrijebiti za vrednovanje teorija i zaključaka od ekološke vrijednosti. Rezultati kemijskih i fizikalnih analiza koje zahtijevaju specijaliziranu i skupocjenu opremu, uređaje, kemikalije i stručno osoblje, ostaju na razini izmjerenih vrijednosti. Ti rezultati se, doduše, koriste pri ocjeni vrijednosti ispitivanog uzorka, ali isključivo vizualnom usporedbom koja je, dakako, nedovoljno pouzdana.

2.4.1. Multivarijantne metode

Sir Ronald Aylmer Fisher smatra se arhitektom *multivarijantne analize (MVA)*. Pronalazak i razvitak kompjuterske tehnologije izazvao je revoluciju u znanstvenim istraživanjima, posebice u multivarijantnoj statističkoj analizi, čije su novije tehnike isključivo vezane uz primjenu računala.⁴⁷ Multivarijantna analiza grana je statistike koja se bavi analizom višestrukih izmjera većeg broja varijabli na jednom ili više uzoraka jedinki. Zanimanje multivarijantnog analitičara za zajedništvo njegovih p mjerenja na N subjekata opisao je Kendall⁴⁸: “Varijable su međusobno toliko ovisne da jedna ili više njih ne može biti izdvojena od ostalih i razmatrana za sebe. Varijable se moraju razmatrati zajedno.” Metode multivarijantne statističke analize razvijale su se postupno i do sada su mnoge našle primjenu u određivanju kvalitete otpadnih voda.

Cooley i Lohnes, kao i Kendall, razlikuju *analize zavisnosti varijabli* kojoj je tipični predstavnik multipla regresija, i *analize međuzavisnosti varijabli* sa tipičnim predstavnikom u analizi glavnih komponenta.⁴⁹

Kshirsagar smatra da je regresijska analiza najvažnija statistička tehnika, što je karakteristični primjer multivarijantnog normalnog gledišta.⁵⁰

Iako se Gifi i kritički osvrnuo na rad spomenutih autora, neke činjenice o multivarijantnim metodama statističke analize su nepobitne.⁵¹ Teoretičari su sistematizirali i klasificirali multivarijantne metode na različite načine.

Klasifikacije analitičkih metoda po Kendalovoj ideji podržava i Sharma, što je prikazano u tablicama 5 i 6.⁵²

Tablica 5. Statističke metode temeljene na *zavisnosti*:

VARIJABLE	ZAVISNA(e)			
	Jedna		Više	
NEZAVISNA(e)	mjerna	kategorijska	mjernih	kategorijskih
<i>Jedna:</i>				
mjerna	• Regresija	• Diskriminantna analiza • Logistička regresija	• Kanonička korelacija	• Multiple-group diskriminantna analiza (MDA)
kategorijska	• t – test	• Diskretna diskriminantna analiza	• MANOVA	• Diskretna MDA
<i>Više:</i>				
mjernih	• Multipla regresija	• Diskriminantna analiza • Logistička regresija	• Kanonička korelacija	• MDA
kategorijskih	• ANOVA	• Diskretna diskriminantna analiza • Conjoint analiza	• MANOVA	• Diskretna MDA

Tablica 6. Statističke metode temeljene na *međuzavisnosti*:

VARIJABLE	T i p	
	mjerne	kategorijske
2	<ul style="list-style-type: none"> Jednostavna korelacija 	<ul style="list-style-type: none"> Dvosmjerna tablica kontingencije Loglinearni modeli
više od 2	<ul style="list-style-type: none"> Analiza glavnih komponentata (PCA) Faktorska analiza (FA) 	<ul style="list-style-type: none"> Višesmjerna tablica kontingencije Loglinearni modeli Analiza korespondencije

Podjela multivarijantnih metoda koja se temelji na *zadanim ciljevima* prikazana je u tablici 7.^{49,53}

Statističko modeliranje kvalitete otpadnih komunalnih voda opisali su u svom radu Velinova i dr.⁵⁴

Tablica 7. Metode multivarijantne analize i autori koji su dali najveći doprinos u njihovoj razradi i primjeni

C I L J	M E T O D E
<i>Stupanj povezanosti</i>	<ul style="list-style-type: none"> Multipla korelacija i regresija (PEARSON, 1901, FISHER, 1928, CATTELL, 1949.) Kanonička korelacija (HOTELLING, 1936.) Multipla analiza frekvencija (diskretne var.)
<i>Značajnost razlika između grupa</i>	<ul style="list-style-type: none"> Faktorijska ANOVA (FISHER, 1923.) Faktorijska ANCOVA (COCHRAN, 1957.) Faktorijska MANOVA (WILKS, 1932.) Faktorijska MANCOVA Jednosmjerna MANOVA ili Hotelling's T^2 (HOTELLING, 1936.) Profile analysis - PA (CRONBACH, 1953.)
<i>Predikcija pripadnosti grupa</i>	<ul style="list-style-type: none"> Jednosmjerna diskriminantna analiza – DA (FISHER, 1936.) Faktorijska diskriminantna funkcijska analiza - DFA
<i>Struktura veze:</i> - empirijska - teoretska	<ul style="list-style-type: none"> Analiza glavnih komponentata – PCA (HOTELLING, 1933.) (Principal components analysis) Faktorska analiza – FA (HARMAN, 1960, CATTELL 1965.)

2.4.2. Klaster analiza

Klaster analiza je vrsta multivarijantne statističke analize koja spada u metode klasificiranja. Temelji se na matematički formuliranim mjerama sličnosti i obuhvaća različite postupke, algoritme i metode grupiranja podataka. Osnovni problem s kojim se istraživači susreću u praksi je na koji način najprije organizirati sakupljene podatke, a zatim koji

algoritam najbolje upotrijebiti. Klaster analiza spada u istraživačke analize čiji je osnovni cilj sortirati različite podatke u grupe na način da se maksimizira stupanj sličnosti unutar grupe uz uvjet da je sličnost s drugim grupama minimalna.⁵⁵

Matrica podataka može se zapisati u obliku:

$$Y = y'_1, y'_2, \dots, y'_n, = y(1), y(2) \dots y(p) \quad (3)$$

pri čemu je svaka komponenta $y'_i, i=1, 2, \dots, n$ redak matrice podataka, a svaki $y(j), j=1, 2, \dots, p$ je stupac koji sadrži opažene vrijednosti j -te varijable. Općenito se nastoji retke grupirati u g klastera. Dva osnovna pristupa hijerarhijskom klasteriranju su aglomerativno klasteriranje i podjela.

2.4.3. Analiza glavnih komponentata

U statistici, *analiza glavnih komponentata*, *Principal Component Analysis (PCA)* je tehnika koja se može iskoristiti za pojednostavljenje skupa podataka. Formalno, to je transformacija koja bira novi koordinatni sustav za skup podataka, takav da najveća varijanca bilo koje projekcije skupa podataka leži na prvoj osi (prva glavna komponenta), druga najveća varijanca na drugoj osi itd. PCA koristimo za smanjenje dimenzionalnosti podatkovnog skupa, uz zadržavanje onih karakteristika podataka koje najviše doprinose varijanci.⁵⁶

Maksimalni broj novih varijabli koji se može formirati jednak je broju izvornih, a nove varijable nisu međusobno korelirane.

Često se uz analizu glavnih komponentata veže faktorska analiza (FA), bliska, ali konceptijski različita tehnika. Mnogi autori drže da je PCA specifičan oblik FA koji nastaje u trenutku odluke o metodi analize: iz ukupne varijance tj. sume varijanci svih varijabli, kao što je to u PCA, ili samo iz onog dijela ukupne varijance koja je zajednička svim varijablama, kao u FA. Razlog više toj tezi je i činjenica da se PCA u nekim statističkim paketima (npr. SPSS, STATISTICA) pronalazi kao opcija FA.

Glavni aspekti analize glavnih komponentata su sažimanje i analiza linearne povezanosti većeg broja multivarijatno distribuiranih, kvantitativnih, međusobno koreliranih varijabli u smislu njihove kondenzacije u manji broj komponenti, novih varijabli, međusobno nekoreliranih, s minimalnim gubitkom informacija.

Ulazni podaci za analizu glavnih komponentata čine p varijabli i n opažaja (individua) i imaju oblik matrice $p \times n$. (tablica 8.)⁵⁶

Tablica 8. Prikaz ulaznih podataka za analizu glavnih komponentata

Opažaj	Variable			
	X_1	X_2	X_3	X_p
1	X_{11}	X_{12}	X_{13}	X_{1p}
2	X_{21}	X_{22}	X_{23}	X_{2p}
:	:	:	:	:
n	X_{n1}	X_{n2}	X_{n3}	X_{np}

Cilj analize je kreiranje p linearnih kombinacija izvornih varijabli koje se nazivaju *glavne komponente (principal components)*⁵⁶:

$$\xi_1 = w_{11}X_1 + w_{12}X_2 + \dots + w_{1p}X_p \quad (4)$$

$$\xi_2 = w_{21}X_1 + w_{22}X_2 + \dots + w_{2p}X_p \quad (5)$$

$$\xi_p = w_{p1}X_1 + w_{p2}X_2 + \dots + w_{pp}X_p \quad (6)$$

gdje su $\xi_1, \xi_2 \dots \xi_p$, p glavnih komponentata i w_{ij} su koeficijenti (*weights*) tj. konstante koje čine koeficijente j -te varijable za i -tu glavnu komponentu.

Zaključak je da analiza glavnih komponentata nastoji reducirati dimenzije grupe ili ih barem razmjestiti bolje kako bi nova baza opisivala tipični model grupe pa se može reći da je u stvari cilj PCA reduciranje radnog prostora.

Pristup nelinearne dinamičke analize glavnih komponentata (ND-PCA) razvila je grupa kineskih autora.⁵⁷ Njihov rad je utemeljen na dinamičkoj PCA i na temelju sigma funkcije dobivene prema neuronskoj mreži (SBFN). Rezultati pokazuju da ovakav predloženi pristup obavlja dobro sposobnost početnog dijagnosticiranja i ukupni stupanj ispravnosti dijagnosticiranja. Primjer korištenja PCA u kombinaciji s neuronskim mrežama možemo uočiti u radu grupe brazilskih autora.⁵⁸ Ovaj rad predstavlja način kako predvidjeti biološku potrošnju kisika (BPK₅) izlaznog toka postrojenja za biološko pročišćavanje otpadne vode. Najbolje predviđanje izvedbe je postignuto kada su podaci predobrađeni koristeći analizu glavnih komponentata (PCA) prije nego su pohranjeni umnoženom neuronskom mrežom.

Analiziran je utjecaj ulaznih varijabli i predviđeni zadovoljavajući rezultati su dobiveni za optimalne situacije.

U radu sa PCA očekuje se da će većina novih varijabli činiti šum – *noise*, i imati tako malu varijancu da se ona može zanemariti, tj. da će većinu informacija ponijeti prvih nekoliko ξ varijabli - glavnih komponenti, čije su varijance značajne veličine. Dakle, iz velikog broja izvornih varijabli kreirano je tek nekoliko glavnih komponenti koje nose većinu informacija i čine glavni oblik - *pattern*.

No, nije uvijek tako. Ako su izvorne varijable nekorelirane analiza ne daje povoljne rezultate. Najbolji rezultati mogu se postići kad su izvorne varijable visoko pozitivno ili negativno korelirane. Tada se može očekivati da će npr. 20-30 varijabli biti obuhvaćeno sa 2 ili 3 glavne komponente.

Pretpostavke za primjenu analize glavnih komponentata više su konceptualne, nego statističke. PCA nije osjetljiva na probleme normalnosti, linearnosti i homogenosti varijanci. Kako je izneseno, određena doza multikolinearnosti čak je i poželjna.

Osnovni koraci u analizi glavnih komponentata su sljedeći:⁵⁹

1. budući da je većina biometričkih setova podataka konstruirana iz varijabli različitih skala i jedinica mjerenja, standardizirati varijable tako da im je prosjek 0, a varijanca 1 kako bi sve bile na jednakoj razini u analizi,
2. izračunati matrice korelacija između svih izvornih standardiziranih varijabli,
3. pronaći svojstvene vrijednosti glavnih komponentata,
4. odbaciti one komponente koje su nositelji proporcionalno malog udjela varijance (obično prvih nekoliko nose 80% - 90% ukupne varijance što će se bolje uočiti nakon razrade faktorske analize).

Osnovu za interpretaciju glavnih komponentata čine svojstveni vektori. Njihove vrijednosti su u prvoj glavnoj komponenti, najčešće, relativno ravnomjerno raspoređene po svim izvornim varijablama. U drugoj glavnoj komponenti dolazi do njihove veće disproporcije, što omogućava izdvajanje izvorne varijable (ili tek nekoliko njih) sa jačim učešćem i pomaže u objašnjavanju i sažimanju ukupne varijabilnosti.

Skorovi glavnih komponentata mogu poslužiti još i:

1. za daljnju interpretaciju rezultata grafičkim predstavljanjem. Tako se njihov relativni međusobni položaj može i vizualno ispitati.

2. kao ulazne varijable u drugim multivarijatnim metodama kao npr. klaster, regresijska i diskriminantna analiza. Prednost korištenja skorova je u tome što nove varijable nisu međusobno korelirane čime je riješen problem multikolinearnosti. No, probleme druge vrste tada može izazvati nemogućnost smislene interpretacije glavnih komponenata.

2.4.4. Faktorska analiza (FA)

Faktorska analiza, Factor Analysis, (FA), statistički je pristup za analizu strukture međusobnih odnosa većeg broja varijabli definiranjem seta zajedničkih skrivenih dimenzija tj. *faktora*.

U faktorskoj analizi, kao i u analizi glavnih komponenata, osnovna je ideja još uvijek da set od p varijabli (i n individua) može biti definiran manjim brojem faktora, pa tako može poslužiti kao redukcijska metoda. No, primarni je cilj identifikacija faktora i određivanje stupnja do kojeg su izvorne varijable objašnjene svakom dimenzijom - faktorom. Za razliku od PCA koja nije bazirana ni na kakvom statističkom modelu, FA je određena specifičnim statističkim modelom.

Zajednički (common) faktor nevidljiva je, hipotetska varijabla koja pridonosi varijanci iz barem dvije izvorne varijable. Izraz faktor najčešće se odnosi na zajednički faktor.

Jedinstveni ili specifični (unique) faktor, također je nevidljiva, hipotetska varijabla koja pridonosi varijanci u samo jednoj izvornoj varijabli.

Opći model zajedničkih faktora je prema SAS Institute⁵¹:

$$y_{ij} = x_{i1}b_{1j} + x_{i2}b_{2j} + \dots + x_{iq}b_{qj} + e_{ij} \quad (7)$$

gdje je: y_{ij} vrijednost i -tog opažaja u j -varijabli

x_{il} vrijednost i -tog opažaja u k -tom zajedničkom faktoru

b_{kj} regresijski koeficijent k -tog zajedničkog faktora za predikciju j -te varijable

e_{ij} vrijednost i -tog opažaja u j -tom jedinstvenom, specifičnom faktoru

q broj zajedničkih faktora

uz pretpostavku da sve varijable imaju prosječnu vrijednost 0.

U matričnom obliku ove jednadžbe mogu se reducirati na:

$$Y = XB + E \quad (8)$$

gdje je X matrica faktorskih opterećenja. B je matrica zajedničkih faktora.

Faktorska opterećenja (factor loadings) jednostavne su korelacije između bilo koje izvorne varijable i faktora, i ključ su za razumijevanje prirode samog faktora.

Iako se i PCA i FA svrstavaju u redukcijske metode, razlike su bitne:

- cilj PCA je reducirati broj varijabli na nekoliko novih komponenti tako da svaka komponenta tvori novu varijablu, koje tada objašnjavaju maksimalni iznos ukupne varijance u podacima,
- cilj FA je identificirati faktore koji mogu objasniti interkorelacije originalnih varijabli i time odrediti strukturu varijabilnosti.

2.4.5. Višestruka regresija

Višestruka regresija (Multiple Regression), statistička je metoda za analizu povezanosti kvantitativnih varijabli i to: između jedne zavisne i više nezavisnih varijabli. Može se opisati modelom:

$$y = f(x_1, x_2, \dots, x_i, \dots, x_k) + \varepsilon \quad (9)$$

U navedenom modelu y je *zavisna varijabla*. To je pojava čije se varijacije izražavaju pomoću nezavisnih (regresorskih) varijabli x_1, x_2, \dots, x_k . Varijabla ε izražava nepoznata odstupanja od funkcionalnog odnosa.

Viševarijantni linearni model (MLR) sa 16 varijabli te model lokalne linearne regresije (PLR) sa 17 varijabli prikazan je u radu M. Čurlin i dr..⁶⁰

Multivarijantnu analizu u svom radu su koristili i Tomita et al.⁶¹ koji su obradili postupak pročišćavanja otpadnih voda aktivnim muljem koristeći 12 fizikalnih varijabli. Ove tzv. kros-korelacijske varijable su pretvorene u nove koje nisu povezane pomoću PCA, moćnog alata za analize, monitoring i dijagnostiku postupaka obrade otpadnih voda. Upravo tri glavne komponente najviše objašnjavaju sustav ukupne varijabilnosti (78% ukupne varijance). Dakle, sposobnost opisa ukupnih karakteristika procesa koristeći jedino tri glavne komponente, učinit će analizu, monitoring i dijagnostiku sustava lakšom. Otkrivene su tri gupe varijabli koje karakteriziraju sustav. Prva grupa identificira varijable koje predstavljaju mikroorganizme i inertne čestice koje proizlaze iz propadanja stanica, dok druga grupa se odnosi na podloge i stupanj protoka. Treća grupa je vezana za pH. Prema ovim rezultatima,

ovaj rad pokazuje kako za proširiti načine tumačenja karakteristika aktivnog mulja koji se koristi u pročišćavanju otpadnih voda.

Primjer korištenja MVA možemo vidjeti i radu grupe znanstvenika iz Tunisa.⁶² Oni su skup kvantitativnih opisa i analitičkih podataka s jednog postrojenja za obradu otpadnih voda u Tunisu, obradili s multivarijantnom statističkom tehnikom u cilju istraživanja evolucije kvalitete otpadnih voda, u vremenskom periodu od 12 godina, za šest fizikalno-kemijskih i bioloških parametara. Eksperimentalnih 6x12 matrica je analizirano putem PCA. Istraživanje korelacije dozvoljenih matrica ka otkrivanju jakih veza između nekih varijabli (BPK_i, KPK_i, ST_i, BPK_o, KPK_o, ST_o) kao i nedostatak veze između ostalih (T i SS_o). PCA pokazuje postojanje do tri značajne PC_s koje se odnose za 74% varijanci. Prva je dodijeljena vodi s nižim organskim opterećenjem dok su druga i treća vezane za vodu s prosječnim i višim organskim i mineralnim opterećenjima. Ova studija predstavlja nužnost i korisnost multivarijantne tehnike za evaluaciju i tumačenje širih kompleksnih skupova podataka s osvrtnom na dobivanje bolje informacije o kvaliteti vode i izgledu mreže monitoringa za učinkovito upravljanje resursima otpadnih voda.


2.4.6. Nelinearni regresijski model

Pod nelinearnim regresijskim modelom podrazumijeva se regresijski model nelinearan u parametrima. Postoji li transformacija kojom se polazni nelinearni model linearizira, model će se analizirati kao model višestruke linearne regresije.

2.5. Modeliranje postrojenja za obradu otpadne vode

Modeliranje postrojenja za pročišćavanje otpadnih voda je koristan alat za izvedbu procjene kapaciteta postrojenja i poboljšanja poslovanja postrojenja, dakle, štedi energiju i smanjuje troškove.

No, modeliranje nije jednostavan zadatak za rješavanje komunalnih problema. Oni mogu zahtijevati pomoć od stručnjaka u izradi okvirnog modela prema kojem će se rješavati ovi problemi. Modeliranje uređaja za pročišćavanje otpadnih voda uključuje nekoliko koraka kako je prikazano na slici 11.⁶³



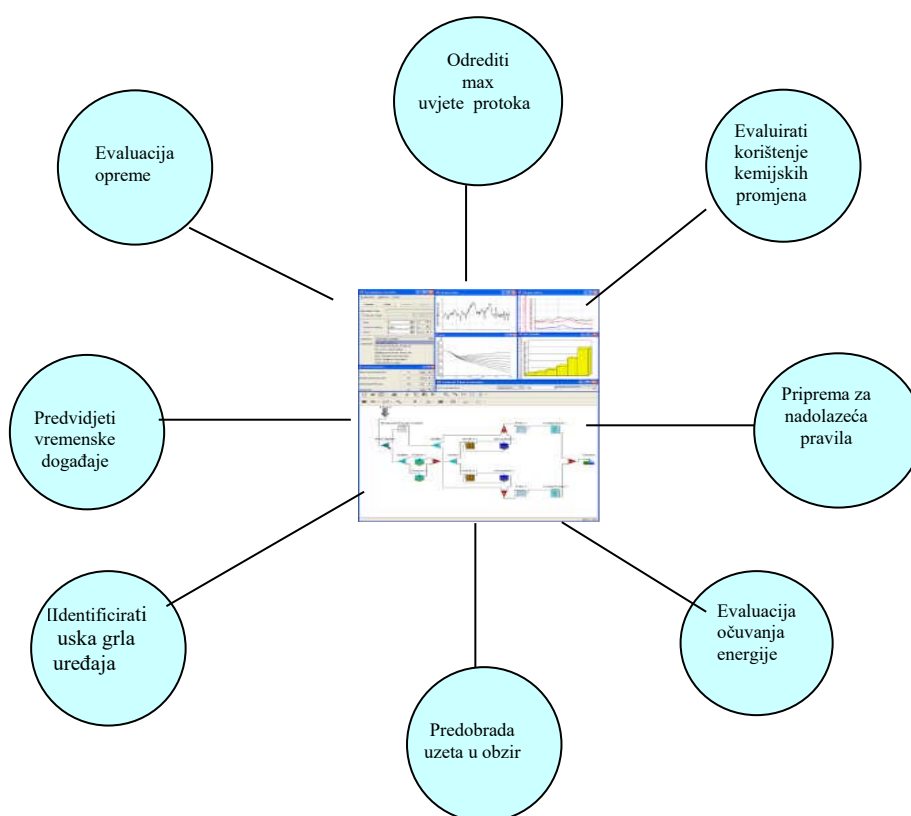
Slika 11. Shematski prikaz koraka u postupku modeliranja

To je interaktivan proces u prirodi. *Prva aktivnost* je određivanje ciljeva modela. Obično kalibriranje složenosti i razine modela ovisi o njegovoj namjeni. *Drugi korak* je prikupljanje podataka o povijesti uređaja i dodatnim informacijama o uređaju dobivenim kroz program uzimanja uzoraka. *Treći korak* je analiza podataka koja uključuje bilancu mase koja se koristi u inženjerskoj literaturi, podatke o monitoringu i ručne izračune. *Četvrti korak* je postavka modela i kalibracija koja uvodi analizirane podatke u model. Nakon što su svi podaci kompletirani, modelar podešava nekoliko parametara modela ka oponašanju procesa na postrojenju. Ako neki drugi skup neovisnih podataka postane dostupan, model preporučuje

njihovu verifikaciju. Konačno, nekoliko simulacija modela mogu se izvoditi prema različitim scenarijima za bolje razumijevanje ograničenja uređaja ili odgovoriti procesnim promjenama.⁶⁴

Modeliranje dokazuje da može biti operaterov najbolji prijatelj tako da on može razumjeti i optimizirati proces. Nakon završetka provedbe i kalibracije, model nudi mnoge prednosti kao što su štednja značajnih troškova predviđanjem ishoda procesnih promjena, kao i obavljanje analize troškova energije. Slika 12. prikazuje model iskorištenja koji uključuje i primjere kako komunalne tvrtke koriste modeliranje svojih uređaja.

Modeliranje uređaja za pročišćavanje otpadnih voda (UPOV) je koristan alat za obavljanje procjene kapaciteta postrojenja i poboljšanja poslovanja postrojenja; ipak, modeliranje nije jednostavan zadatak za komunalnu djelatnost.⁶⁴



Slika 12. Model iskorištenja

Iako je uloženo mnogo truda za olakšavanje i promicanje prijateljskog korištenja alata za računalne simulacije od strane lokalne zajednice, modeliranje u praksi zahtijeva određenu razinu razumijevanja procesa i modela. Odlična ideja za komunalnu djelatnost je posezanje za pomoći stručnjaka pri stvaranju okvira modela na kojem se ova djelatnost može učiti i izgrađivati.

2.5.1. Modeliranje procesa obrade otpadne vode

Analiza procesa biološke obrade otpadne vode vrši se svakodnevnim mjerenjem različitih veličina koja ukazuju na uspješnost procesa (kvalitetu sirove i obrađene otpadne vode, uvjete u kojima uređaj radi te kvalitetu aktivnog mulja).⁶⁰ Na kompleksnost procesa dodatno utječu nestalnost sastava i protoka otpadne vode koji imaju direktan utjecaj na sastav i aktivnost mješovite mikrobne kulture. Te parametre je moguće odrediti na kraju procesa što uvelike otežava optimalno vođenje procesa. Ako dođe do nezadovoljavajućih vrijednosti ne postoji mogućnost naknadnog reagiranja u procesu.

Iz tog razloga već godinama se nastoji unaprijediti optimalno upravljanje procesom pomoću razvijanja modela koji bi omogućili vjernije prikazivanje dinamike procesa, identificirali problematične točke procesa te ponudili moguća rješenja.

Stalnom ocjenom procesa moguće je znatno smanjiti kasnije proizvodne troškove i troškove zbrinjavanja otpada i nusprodukata, odnosno racionalno gospodariti prirodnim izvorima u skladu s modernim zahtjevima u razvoju održivih procesa. Za modeliranje biotehnoloških procesa koriste se različiti modeli koji se mogu podijeliti na nestrukturane i empirijske modele.⁶⁵

2.5.1.1. Nestrukturani modeli

Nestrukturani modeli nazivaju se i mehanistički tj. (eng. white box models) jer zahtijevaju dobro poznavanje procesa. Ovi modeli se zasnivaju na uobičajenim bilancama mase i jednadžbama koje opisuju brzinu rasta mikroorganizama, potrošnju supstrata i formiranje produkta.⁶⁶

Nestrukturani modeli procesa pročišćavanja aktivnim muljem poznati kao Activated Sludge Models ili skraćenica ASM 1, 2 i 3, najčešće su primjenjivani modeli za simulaciju biološkog pročišćavanja voda. ASM modeli opisuju dvije najvažnije faze ovog postupka –

biološku oksidaciju i naknadno (sekundarno) taloženje.⁶⁷ Ovisno o stupnju obrade otpadne vode u pojedinom sustavu, uključuje li on i nitrifikaciju ili denitrifikaciju i uklanjanje fosfora, za modeliranje tog procesa primijeniti će se jedna od tri postojeće varijacije modela.

ASM1⁶⁴ se može smatrati kao referentni model jer je bio prvi prihvaćen u istraživačkim jedinicama, a kasnije i u industriji. On je prvenstveno razvijen za postrojenja koja obrađuju komunalnu otpadnu vodu, kako bi opisao uklanjanje organskog ugljika i dušika uz simulaciju potrošnje kisika i nitrata kao akceptora elektrona i predvidio rezultate obrade otpadne vode aktivnim muljem. ASM1 je postao referenca za mnoge znanstvene i praktične projekte zbog čega je znatno i proširivan, primjerice, kako bi dobili veći broj eksperimentalnih opažanja povezano je više frakcija KPK, zatim opisali rast i dinamiku razmnožavanja pri formiranju flokula i filamentoznih bakterija, te ustanovili nužnost sadržaja novog procesa uklanjanja fosfora. Rezultat tog proširenja ASM1 vezanog uz uklanjanje fosfora dobili su se ASM2 i ASM2d modeli.

ASM3 model ima u osnovi iste ciljeve kao i ASM1, a također je razvijen za biološko uklanjanje dušika. On je namijenjen da postane novi standardni model, koji ima za zadaću ispravljanje brojnih nedostataka koji su se pojavili tijekom korištenja ASM1 modela. Glavna razlika između ta dva modela je da ASM3 model prepoznaje važnost skladištenja organske tvari (polimera) kod heterotrofnih organizama.⁶⁸ U ASM3 modelu se pretpostavlja da se sav biorazgradiv supstrat koristi i pohranjuje kao polimer unutar stanice koji se koristi za rast.

Ovi modeli su poprilično složeni, a odabir pojedinog zavisi od stupnja obrade otpadne vode u pojedinom sustavu. Na temelju jednadžbi bilanca tvari definirane su jednadžbe modela:⁶⁷

$$\frac{d\gamma_{Si}}{dt} = (\gamma_{Si,ul} - \gamma_{Si}) \cdot \frac{q_{v,ul}}{V} - r_{S,i} \quad (10)$$

$$\frac{d\gamma_{O_2}}{dt} = (\gamma_{O_2,ul} - \gamma_{O_2}) \cdot \frac{q_{v,ul}}{V} - r_{O_2} + r_{aer} \quad (11)$$

$$\frac{d\gamma_{Xi}}{dt} = (\gamma_{Xi,ul} - \gamma_{Xi}) \cdot \frac{q_{v,ul}}{V} + r_{X,i} - r_{d,i} \quad (12)$$

γ_{Si} = koncentracija otopljenog supstrata i (kg m^{-3}); $i = \sum \{\text{biorazgradljiva organska tvar,}$

inertna organska tvar , inertna organska tvar, dušik u obliku amonijaka, nitrata, itd.}

γ_{O_2} = koncentracija otopljenog kisika (kg m^{-3});

γ_{Xi} = koncentracija pojedinog mikroorganizma u satavu aktivnog mulja (kg m^{-3});

$i = \sum \{\text{heterotrofne bakterije, autotrofne bakterije, protozoa, bičasti, itd.}\}$

$r_{S,i}$ = brzina razgradnje pojedinog supstrata ($\text{kg m}^{-3} \text{ h}^{-1}$);

$r_{X,i}$ = brzina odumiranja pojedinog mikroorganizma ($\text{kg m}^{-3} \text{ h}^{-1}$);

$r_{d,i}$ = brzina rasta pojedinog mikroorganizma ($\text{kg m}^{-3} \text{ h}^{-1}$);

r_{O_2} = brzina potrošnje kisika od strane mikroorganizma ($\text{kg m}^{-3} \text{ h}^{-1}$);

$r_{aer} = K_L a \cdot (c_S - c_L)$; brzina aeracije ($\text{kg m}^{-3} \text{ h}^{-1}$);

$K_L a$ = volumni koeficijent brzine prijenosa kisika (h^{-1});

c_S = maksimalna moguća koncentracija otopljenog kisika (kg m^{-3});

c_L = koncentracija otopljenog kisika (kg m^{-3});

$q_{v,ul}$ = protok sirove otpadne vode, ulazni tok ($\text{m}^3 \text{ h}^{-1}$);

V = volumen aeracijskog bazena (m^3);

2.5.1.2. Empirijski modeli

Empirijski modeli nazivaju se i statistički tj. (eng. black box models) jer ne zahtijevaju poznavanje procesa pa su samim time i jednostavniji.

Oni daju bolje rezultate jer se empirijski modeli zasnivaju na statističkoj analizi eksperimentalnih podataka kojih obično ima veliki broj.⁶⁹ Kako bi se smanjio broj varijabli tj. eliminirale one koje nemaju direktan utjecaj na proces radi se prethodna obrada podataka. Na taj način ostaju varijable koje su bitne te se utvrđuje njihova međusobna zavisnost koja se prikazuje funkcijom – jednadžbom modela.

Zavisno od prirode funkcije razlikuju se linearni i nelinearni modeli.

Linearni empirijski modeli najčešće se koriste za opisivanje linearnih, ali i nelinearnih procesa, poput složenih biotehnoloških procesa. Izgradnja tih modela temelji se na primjeni postupaka modeliranja poput viševarijantne linearne regresije (eng. Multiple Linear Regression, MLR) ili metode djelomičnih najmanjih kvadrata (eng. Partial Least Squares, PLS).


Nelinearni empirijski modeli koriste neke od uobičajenih nelinearnih funkcija pomoću kojih se pokušava opisati proces. Kako su biotehnološki procesi po prirodi uglavnom nelinearni, ovi modeli daju bolje rezultate od linearnih.⁶⁰

U skupinu empirijskih modela pojedini autori ubrajaju i modele umjetne inteligencije (eng. Artificial Intelligence) kao što su modeli neuronskih mreža (eng. Neural Network Models).

Modeli neuronskih mreža su vrlo praktični za predviđanje rezultata nelinearnih procesa jer ne zahtijevaju složene matematičke proračune i određivanje sistemskih parametara. Oni se također zasnivaju na analizi eksperimentalnih podataka.

Matematički model neuronske mreže sastoji se od velikog broja neurona (slika 11). Neuroni mogu biti međusobno povezani na različite načine te tako tvore različite tipove neuronskih mreža.

Osnovna organizacija neurona sastoji se od 3 sloja: ulazni sloj, unutarnji sloj i izlazni sloj.⁶⁵



Slika 11. Shematski prikaz matematičkog dijela neurona

x_i - ulazni signali iz okolnih neurona

w_i - težinski koeficijenti (predstavljaju jakost utjecaja pojedinog signala na aktivnost neurona)

Složenije mreže mogu imati i više unutarnjih („skrivenih“) slojeva koji joj omogućuju baratanje nelinearnim i kompleksnim korelacijama. Broj skrivenih slojeva određuje se metodom pokušaja i pogrešaka i ovisi o specifičnom problemu.

Primjeri dva osnovna tipa neuronskih mreža:

1. višeslojni perceptroni (eng. Multilayer perceptron, MLP) najčešće su karakterizirani sigmoidalnom funkcijom aktivacije neurona,
2. neuronske mreže s kružnom osnovom (eng. Radial Basis Function Neural Network, RBF) najčešće su karakterizirani Gaussovom funkcijom aktivacije neurona.

2.6. Neizrazita logika

Ideja o primjeni tehnike neizrazite logike (Fuzzy logic), za integrirani sustav otpadnih voda je izgledna za uključene sustave karakterizirane svojim varijablama, koncentracijskim pragovima, procesom i opisom komponenata. Mogućnost međusobne korelacije sustava putem jednostavnih pravila i neizrazitih skupova čini jedini način za laku i efikasnu kontrolu integriranog sustava.⁷⁰

Neizrazita logika može biti promatrana kao jezik koji dopušta prevođenje sofisticiranih izvješća iz prirodnog jezika u matematičku formu.⁷¹


Koncept neizrazite logike⁷² uveden je 1965. godine zajedno sa teorijom neizrazitih skupova, a njime je omogućeno modeliranje semantičkih neodređenosti govornog jezika. Neizrazita, ili fuzzy logika danas se koristi u širokom rasponu industrijskih i znanstvenih primjena. Za razliku od klasične logike, kod koje vrijednosti istinitosti mogu poprimiti samo 0 (laž) i 1 (istina), neizrazita logika podržava raspon vrijednosti od potpune laži do potpune istine. Porast zanimanja za neizrazitu logiku započinje tek prije desetak godina, nakon uspješnih primjena u japanskim proizvodima široke potrošnje. Neizrazita logika je fleksibilna, bazirana na prirodnom jeziku i tolerantna na nepreciznost ulaznih podataka, a sve to omogućuje da se neizrazita logika koristi kao moćan alat koji se može izgraditi na iskustvu stručnjaka i njihovom znanju. Neizrazita se logika može objasniti pojašnjavanjem neizrazitih skupova. Neizraziti skup je nadogradnja klasičnog skupa a definira se kao:

$$A = \{x, \mu_A(x) | x \in X\} \quad (13)$$

gdje je $\mu_A(x)$ funkcija pripadnosti x-a u A. Funkcija pripadnosti preslikava svaki element iz X u vrijednosti između 0 i 1.⁷²

Neizrazita logika vrlo je blizu načinu kako čovjek doživljava i u govoru interpretira određene pojave ili stvari u prirodi. Sam pojam kvalitete vode, odnosno na primjer „vrlo dobra“ kvaliteta vode u klasičnom smislu zahtijevala bi točnu granicu ispod koje voda više ne spada u kategoriju „vrlo dobre kvalitete“. U fuzzy pristupu takva granica ne postoji, već je prijelaz iz laži u istinu stupnjeviti i definira se funkcijama pripadnosti. Postoji velik broj funkcija pripadnosti koje se mogu koristiti, a u ovom radu je korištena funkcija Gaussove krivulje definirana funkcijom (slika 12.):

$$f(x; \sigma, c) = e^{\frac{-(x-c)^2}{2\sigma^2}} \quad (34)$$



Slika 12. Primjer Gaussove krivulje

Kod realizacije sustava u ovom primjeru, korišteni su standardni logički operatori i funkcije realizacije tih operatora (min, max,...), a u postupku defazifikacije korištena je metoda centroida. Uz pomoć spomenutih logičkih operatora kreirana su pravila oblika:

AKO x je A i y je B ONDA z je C .

Graf je iscrtan na temelju definiranja pravila za određivanje kvalitete vode.

Koristeći ovu metodu, možemo ustvrditi da indeks kvalitete komunalne vode određuje kvalitetu vode u jezičnim izrazima budući da je neizrazita logika temeljena na pristupu kojem se pripisuje sigurna vrijednost prema različitim jezičnim izrazima. Primjenom programskog jezika MATLAB, uzorak vode može biti klasificiran kao vrlo dobar, dobar, korektan i loš s različitim stupnjevima pripadnostima. Prilične nesigurnosti su ugrađene u proces određivanja kvalitete vode za specifične upotrebe. Eksperimentalni podaci također pružaju mnogo nesigurnosti.

Stoga se sve više koristi neizrazita logika, kao mehanika tehnika računanja s kojom se bolje predstavlja dinamički sustav i otvara novi model za mjerenje komunalnih voda za specifične ciljeve.

Primjeri fuzzy kontrole poremećaja u primjeni postupka obrade otpadne vode su poznati.⁷³ U ovom radu opisan je postupak biološke ili kemijske obrade otpadnih voda koji je podvrgnut širokim fluktuacijama, u protocima i organskim opterećenjima, što često rezultira činom razgradnje ili čak kvarom postrojenja. Uspješno upravljanje ovim kritičnim situacijama uključuje predviđanje i rješenje kompleksa kontrole dizajna, pod pretpostavkom da je on-line informacija o kvaliteti influent postrojenja dostupna i da je to postrojenje opremljeno uređajima za kontrolu protoka kako bi se izmijenio protok uzorka. Tu je nužna primjena učinkovitih tehnika kontrole.

Drugi stručni sustav za praćenje i dijagnoze anaerobnih hibridnih pilot postrojenja za obradu otpadnih voda bio je također uspješno opisan u radu A. Punal i dr.⁷⁴ U ovom radu je primijenjen široki skup operativnih uvjeta, radeći na različitim KPK, stupnjevima organskog opterećenja i hidrauličkog vremena zadržavanja. Sustav je uspješno identificirao dvije učestale neprirodne situacije, hidraulično i organsko preopterećenje. U oba slučaja, ovaj sustav dostavlja vrijedne preporuke i nakon anaerobne obrade, u kratkom vremenu, otpadne vode se vraćaju u svoje normalno stanje.

Za stanje i kontrolu preopterećenja u anaerobnim postrojenjima za obradu otpadnih voda (AWTP) koristeći načela neizrazite logike bili su zainteresirani Murnleitner i dr.⁷⁵ Sustav baziran na načelima neizrazite logike je dizajniran za obradu vrlo jakih fluktuacija u koncentraciji supstrata i stupnja volumetrijskog opterećenja. Koncentracija vodika zajedno s koncentracijom metana, stupnjem proizvodnje plina, pH i razinom punjenja spremnika kiselim tamponom upotrijebljene su kao input varijable za sustav neizrazite logike. Rukovane varijablama bile su stupanj protoka od kiselog tampon spremnika u metan reaktoru, temperatura i pH u oba reaktora, stupanj cirkulacije fiksnog ležećeg reaktora, povratni protok od metanskog reaktora u zakiseljavanje i kontrola punila u kiselom tampon spremniku. Autori su proveli istraživanje u dvostupanjskoj laboratorijskoj skali AWTP i zaključili da stanje opterećenosti postrojenja za obradu može biti prepoznato mjerenjem vodika, metana, pH i stupnja plinovitosti, gdje su bili dostupni ekonomični senzori.

Drugi autori su opisali simulirani i evaluirani fuzzy sustav kontrole u postrojenju za obradu s aktivnim muljem.⁷⁶

Ova studija je ustanovljena na razvijenom visokom stupnju fuzzy kontrolora aeracije s boljim karakteristikama od dvaju konvencionalnih kontrolora u obliku potrošnje energije i u isto vrijeme s nešto boljim rezultatima kvalitete otpadne vode.

Vezano za članke o komponentama okoliša (zrak, voda, tlo) jasno je da kemometrija bazirana na principima neizrazite logike, uspješno uvedena u raznim poljima kemije i studija o okolišu. Štoviše, mogu se naznačiti tri glavna cilja: modeliranje, predviđanje i klasifikacija. Sve ovo se može postići koristeći gore navedene tehnike. Neke od ovih tehnika razvijene su isključivo za primjenu u okolišu i karakteristične korisne zahtjeve zadane u nastavku. Za modeliranje i predviđanje (koristeći neuronske mreže ili vremensku serijsku analizu) glavni zadatak je izdvojiti bezvrijedne podatke iz proučavanih uzoraka (predviđanje) ili skupa podataka korištenih u fazi stvaranja pravila modela. Kontinuirano zabilježeni vremenski podaci pri visokim frekvencijama su preporučljivi za ove ciljeve. Klasifikacija izvedena faktorskom analizom ili klaster analizom bazirana na principu neizrazite logike donosi zadovoljavajuće rezultate čak i za nevremenske skupove podataka.

Metode bazirane na fuzzy skupovima obično su zasnovane na stupnjevima neizvjesnosti sa sustavom zaštite okoliša ili modelom kao izlaznom veličinom. Ove metode mogu se također upotrijebiti prema konceptima koji nisu brojčano definirani ili nalaze primjene prema mnogim postupcima odlučivanja kod naizgled nespojivih varijabli iz društvenih i ekonomskih znanosti.⁷⁷

U ovom radu primjene neizrazite logike pri podršci u odlučivanju upravljanja ekosustavom se pregledane i procijenjene s naglaskom na modele s utemeljenim pravilima. Konkretno, identifikacija, optimizacija, provjera valjanosti, interpretacija i aspekti nesigurnosti modela utemeljenih na pravilima neizrazite logike za podršku pri odlučivanju u upravljanju ekosustavom je raspravljana.

Jezični aspekt može biti utemeljen na dva različita pristupa u upravljanju ekosustavom:

(1) stručno znanje i/ili ekološki (monitoring) podaci su dostupni u jezičnom obliku i zbog nepreciznosti prirodnog jezika, bavimo se jezičnim nesigurnostima,

(2) upravljači ekosustavom žele razvijati modele da podrška u odlučivanju bude interpretativna i transparentna.⁷⁸

Pravila neizrazite logike za monitoring zagađenja otpadnih voda teškim metalima iskoristila su dva rumunjska autora koji su pokazali da se primjena neizrazite logike kod

razmatranog sustava sugerira i kod područja gdje tradicionalni kontrolni inženjering već nudi raznovrsna rješenja. Temeljni pojmovi fuzzy tehnologija uspješno su iskorišteni kod modeliranja kvalitete vode.⁷⁹ Uz pomoć programskog jezika MATLAB postavljena su pravila neizrazite logike sačinjenih iz devet varijabli za određivanje kvalitete otpadnih voda. Prema dobivenom indeksu zagađenja vode (0-1) može se odrediti kvalitetu vode kao „lošu“ ili „dobru“. Na ovaj način se olakšava praćenje kvalitete otpadnih voda, omogućuje se planiranje kvalitete vode kao i razine usklađenosti provjere prikupljenih podataka prema standardima zaštite okoliša te se provodi prevencija, sanacija i kontrolne mjere, kako bi se zadovoljili planirani ciljevi kvalitete vode.

3. METODIKA

3.1. Uzorkovanje otpadne vode

Obzirom na visok stupanj nehomogenosti sastava otpadne vode, osnovni zahtjev pri uzorkovanju jest reprezentativnost, tj. uzorak mora imati što sličnije fizikalne, kemijske i biološke značajke kao i voda iz koje je uzet.

Trenutni uzorci predstavljaju u nekom određenom vremenu uzeti dio medija koji se ispituje, dakle preslikavaju stanje sastava otpadne vode u trenutku uzorkovanja. Za dobro definiranje kvalitativnih značajki otpadne vode trenutnim uzorcima, potrebno je izvršiti ispitivanje većeg broja uzoraka.

Kompozitni uzorci se dobivaju iz pojedinih uzoraka, uzetih u pravilnim vremenskim intervalima, sastavljanjem najčešće u dvosatne kompozitne uzorke i to u količinama proporcionalnim protocima u trenutku uzimanja uzoraka.

Način uzimanja uzoraka i učestalost ispitivanja ovise o količini otpadnih voda i načinu pročišćavanja, te o koncentraciji analiziranih tvari u odnosu na maksimalno dozvoljenu koncentraciju (MDK).

Kako se otpadne vode sa šireg područja grada Splita ispuštaju u prirodni recipijent, more, vrši se kontinuirano mjerenje količine otpadne vode na Centralnom uređaju za pročišćavanje otpadnih voda Stupe CUPOV (slika 13.) te na crpnim stanicama (CS) Katalinića brig i Duilovo.



Slika 13. Uređaj za pročišćavanje otpadnih voda Stupe

Otpadne vode iz navedenog sustava odvodnje su razrijeđene. Uzorci su prikupljeni u periodu od 2006. do 2009. godine (4 godine). Područje mjesta uzorkovanja prikazano je na slici 14. Uzimani su ručno posudom za zahvaćanje uzoraka, iza fine rešetke, na kontrolnom oknu neposredno prije podmorskog ispusta, te prelijevani u staklene boce od 1L za kemijsku analizu. Pri svakom uzimanju uzorka izmjerena je temperatura digitalnim termometrom. Za određivanje o-fosfata, amonijaka, nitrata, sulfata i klorida uzorci su filtrirani. Ako analize nisu provedene istog dana, uzorci su čuvani u hladnjaku na temperaturi od +4 °C.



Slika 14. Područje s naznačenim mjestima uzorkovanja

3.2. Određivanje značajki otpadne vode

U Republici Hrvatskoj parametri za kvalitetu voda propisani su Pravilnikom o kvaliteti vode. Prepoznati parametri koji se koriste pri definiranju kvalitete komunalnih voda su slijedeći: *temperatura*, *pH*, *biološka potrošnja kisika (BPK₅)*, *kemijska potrošnja kisika (KPK)*, *ukupni dušik (N)*, *ukupni fosfor (P)*, *suspendirana tvar*, *kloridi*, *sulfati*, *orto-fosfati i detergentsi*. Parametri koji ukazuju na sastav i kakvoću otpadne vode nakon obrade, a neposredno prije ispuštanja u prirodni recipijent (more), određuju se u laboratoriju, uobičajenim analitičkim metodama propisanim u "A Standard Methods for the Examination of Water and Wastewater".⁸⁰

3.2.1. Određivanje ukupnih suspendiranih čestica

Ukupne suspendirane čestice (TSS – Total Suspended Solids) predstavljaju masu u vodi sadržane čvrste faze, koja se izdvaja filtriranjem, a izražava se u mg/L. Određuju se u definiranom volumenu uzorka vode vaganjem nakon sušenja pri 105 ± 2 °C do konstantne odvage.

Filter papir (*Schleicher & Schuell GF 8, glass fibre papers, Ø 45 mm*) se suši u posudici za vaganje 1 sat pri temperaturi od 105 ± 2 °C, a nakon hlađenja u eksikatoru izvaže se. 100 mL dobro promiješanog uzorka profiltrira se preko filter papira. Filter papir s uzorkom ponovno se suši u sušioniku 1 sat kod 105 ± 2 °C. Razlika u masi izvaganog filter papira nakon filtracije i samog filter papira podijeljena s volumenom uzorka vode predstavlja količinu ukupnih suspendiranih čestica.

3.2.2. Određivanje kemijske potrošnje kisika (KPK)

KPK označava utrošak jakog oksidansa potreban za oksidaciju u vodi prisutnih organskih tvari, a izražava se u ekvivalentnoj količini kisika, kao mg O₂/L.

Određivanje KPK provodi se u epruvetama 16 x 160 mm s brušenim čepom. U epruvetu se doda 2 mL uzorka dobro promiješanog i homogeniziranog, 2 mL otopine kalij-bikromata (K₂Cr₂O₇) kao sredstva za oksidaciju, te dobro promiješa. Naime, oksidaciji s K₂Cr₂O₇ podliježe preko 95% prisutne organske tvari. Potom se pažljivo uz stijenku epruvete doda 3 mL H₂SO₄ koja se priprema otapanjem AgSO₄ u koncentriranoj sulfatnoj kiselini, pošto AgSO₄ služi kao katalizator koji potpomaže potpuniju oksidaciju organskih sastojaka koji teže oksidiraju. Nakon što se epruveta začepi i dobro protrese kako bi se slojevi pomiješali, postavi se na stalak i ostavi 2 sata pri temperaturi od 150 °C. Nakon hlađenja, sadržaj epruvete se prebaci u Erlenmeyerovu tikvicu, a višak kalij-bikromata zaostao nakon oksidacije titrira se s 0,05 mol/L otopinom feroamonij-sulfata [Fe(NH₄)₂(SO₄)₂ x 6H₂O] do promjene boje iz plavozelene u crvenosmeđu. Zbog nestabilnosti otopine feroamonij-sulfata (FAS) odredi se stvarna koncentracija otopine titracijom standardne otopine kalij-bikromata s feroamonij-sulfatom.

Na isti način napravi se slijepa proba s destiliranom vodom.

$$KPK \text{ (mg O}_2\text{/L)} = \frac{[V(FAS)_{sp} - V(FAS)_{uz}] \times c(FAS) \times \frac{1}{4} M(O_2)}{V_{uz}} \times 1000 \quad (14)$$

gdje je:

V_{uz} = volumen uzorka

$V(FAS)_{sp}$ = utrošak FAS za titraciju slijepa probe

$V(FAS)_{uz}$ = utrošak FAS za titraciju uzorka

$C(FAS)$ = stvarna koncentracija otopine FA

3.2.3. Određivanje biokemijske potrošnje kisika (BPK₅)

Pod BPK₅ podrazumijeva se količina kisika izražena u mg O₂/L, koja je potrebna za razgradnju organske tvari pod utjecajem mikroorganizama, i to kod 20°C u trajanju od 5 dana inkubacije u tami.

Najmanje dvije Winkler-ove boce napune se dobro homogeniziranim uzorkom ispitivane vode. U jednu bocu se dodaju reagensi za fiksiranje kisika radi određivanja kisika odmah ili najkasnije 24 sata nakon fiksiranja. Druga boca se inkubira u termostatu kod 20°C kroz 5 dana radi određivanja kisika nakon inkubacije. Boce se zatvaraju kosim čepom kako bi se uklonili mjehurići zraka koji mogu utjecati na dobivene vrijednosti izmjerene koncentracije otopljenog kisika. Obično se radi nekoliko razrjeđenja otpadne vode kako bi se smanjio broj mikroorganizama u jedinici volumena. Naime, veliki broj mikroorganizama u otpadnoj vodi dovodi do prebrze potrošnje kisika, pa se BPK₅ ne može izračunati. Stupanj razrjeđenja ovisi o vrsti otpadne vode. Voda za razrjeđivanje priprema se iz otopina hranjivih soli.

U bocu iz koje se određuje količina kisika odmah se doda pipetom ispod površine vode 1 mL otopine MnSO₄ ili MnCl₂ i 1 mL alkalne otopine KJ i dobro promiješa. Kad se talog slegne, otopina iznad taloga se oprezno odstrani vodenom sisaljkom, doda se 2 mL razrijeđene H₂SO₄ (1:1) i promiješa kako bi se talog otopio. Tako dobivena otopina titrira se s 0,01 mol/L otopinom Na₂S₂O₃ svježe pripremljenom kojoj se prethodno odredi točna koncentracija, uz škrob kao indikator. Titracija se provodi do obezbojenja.

Paralelno se radi slijepa proba sa destiliranom vodom, kao korekcija koja se oduzima od konačnog rezultata za BPK₅.

BPK₅ se izračunava iz razlike sadržaja kisika određenog neposredno nakon pripreme uzorka otpadne vode i kisika preostalog nakon 5 dana inkubacije, prema izrazu

$$BPK_5 \text{ (mg O}_2 \text{ / L)} = \left[\left(\frac{a \times 80 \times f}{V_{boca} - V_{reagensi}} \right)_{odmah} - \left(\frac{a \times 80 \times f}{V_{boca} - V_{reagensi}} \right)_{nakon 5 \text{ dana}} \right] \times R \quad (15)$$

gdje je:

a = ml 0,01 mol/L otopine Na-tiosulfata utrošeni za titraciju uzorka

f = faktor 0,01 mol/L otopine Na-tiosulfata

V_{boca} = volumen Winkler boce (označen na boci)

$V_{reagensi}$ = volumen dodanih reagensa (2 mL)

R = razrjeđenje uzorka

3.2.4. Određivanje klorida

U 50 mL uzorka ili odgovarajući alikvot doda se 1 mL indikatora K_2CrO_4 i titrira s 0,02 M otopinom $AgNO_3$, kojoj je određen faktor do pojave slabo crvene boje. Paralelno se radi slijepa proba s destiliranom vodom.

Koncentracija klorida računa se prema izrazu

$$\gamma_{Cl^-} (mg/L) = \frac{[(V_{AgNO_3})_{uz} - (V_{AgNO_3})_{sp}] \times M \times f \times A_r(Cl)}{V_{uz}} \times 1000 \quad (16)$$

gdje je:

$(V_{AgNO_3})_{uz}$ = mL $AgNO_3$ za titraciju uzorka

$(V_{AgNO_3})_{sp}$ = mL $AgNO_3$ za titraciju slijepa probe

M = molaritet otopine $AgNO_3$

f = faktor otopine $AgNO_3$

$$f = \frac{V_{NaCl} \times 0,02}{V_{AgNO_3} \times 0,02} \quad (17)$$

gdje je:

V_{NaCl} = mL 0,02 mol/L otopine NaCl (10 mL)

V_{AgNO_3} = mL 0,02 mol/L otopine $AgNO_3$

3.2.5. Određivanje sulfata

Pipetira se 100 mL uzorka ili odgovarajući alikvot, doda se 4 mL miješanog reagensa za sulfite (NaCl otopljen u destiliranoj vodi uz dodatak HCl , etilnog ili izopropilnog alkohola i glicerola), te pola žlice $\text{BaCl}_2 \times 2\text{H}_2\text{O}$ sve se miješa na magnetskoj miješalici. Nakon dvije minute na spektrofotometru se očitava apsorbancija kod valne duljine $\lambda = 420 \text{ nm}$.

Paralelno se radi slijepa proba sa destiliranom vodom, kao i korekcija na mutnoću uzorka tako da se u uzorak dodaju sve kemikalije osim barijevog klorida.

Kod pripreme standarda pipetira se odgovarajući volumen standardne otopine u odmjernu tikvicu od 100 mL, a zatim se postupa jednako kao i s uzorcima.

Iz dobivenog baždarnog pravca očitava se koncentracija nepoznatih uzoraka.

3.2.6. Određivanje orto-fosfata

Uzorka od 50 mL ili odgovarajući alikvot potrebno je otpipetirati u odmjernu tikvicu. U svaku tikvicu se doda 1 mL askorbinske kiseline, promiješa i zatim doda 2 mL otopine kiselog molibdata. Nakon razvijanja plave boje (10-30 minuta od dodavanja reagensa), vrši se očitavanje apsorbancije na spektrofotometru kod valne duljine 880 nm.

Paralelno se radi slijepa proba s destiliranom vodom, a ostale kemikalije dodaju se kao u uzorak. Ukoliko se radi korekcija na mutnoću uzorka, koja se može izostaviti, u uzorak se dodaju sve kemikalije osim otopine askorbinske kiseline.

Standardi se rade na isti način kao i uzorci, tako da se umjesto uzorka doda odgovarajući alikvot standardne otopine.

3.2.7. Određivanje amonijaka salicilatnom metodom

U odmjernu tikvicu od 50 mL stavi se do 40 mL uzorka, pri čemu pH treba biti između 5,0 i 8,0. Zatim se doda 4 mL pripravljene salicilat-citratne otopine, promućka, te se doda 4 mL otopine reagensa (izosan G). pH treba iznositi 12,6. Uzorak se nadopuni destiliranom vodom do oznake, promiješa i ostavi stajati 1-3 sata kod 25°C . Najranije nakon 1 sat, a najkasnije prije 3 sata mjeri se apsorbancija na $655 \pm 2 \text{ nm}$ prema slijepoj probi. Kao slijepa proba koristi se destilirana voda s navedenim reagensima.

Na isti način se tretiraju i pripremljeni standardi te se mjerenjem dobije baždarni pravac.

3.2.8. Određivanje nitrita

Za pripremu standardne otopine iz koje se pripravlja serija radnih standarda za izradu baždarnog pravca koristi se natrijev nitrit. Pipetira se određeni alikvot u odmjernu tikvicu od 50 mL i nadopuni destiliranom vodom do oznake. Doda se 1 mL sulfanilne kiseline i 1 mL α -naftilamina i promiješa. Nakon 15 minuta mjeri se apsorbancija kod 500 nm na spektrofotometru. Na isti način postupa se i sa standardima.

Za svaki uzorak se radi i korekcija na mutnoću dodatkom sulfanilne kiseline u uzorak, ali bez α -naftilamina.

3.2.9. Određivanje nitrata uz 2,6-dimetilfenol

U čaše od 100 mL otpipetira se 35 mL smjese kiseline za nitrata (koncentrirana sulfatna kiselina, koncentrirana ortofosforna kiselina i amonijev hidrogensulfid). Zatim se redom u svaku čašu otpipetira po 5 mL standardne otopine ili uzorka, te 5 mL otopine 2,6-dimetilfenola. Dobro se promiješa i ostavi stajati 30 minuta. Paralelno se radi slijepa proba. Mjeri se apsorbancija kod 324 nm.

Mjerenjem apsorbancije pripremljenih radnih standarda dobiva se baždarni pravac iz kojeg se očitaju koncentracije nitrata u uzorcima.

3.3. Analiza rezultata mjerenja

3.3.1. Osnovna statistička analiza pokazatelja onečišćenja komunalne otpadne vode grada Splita

Procjena i modeliranje pokazatelja onečišćenja komunalnih otpadnih voda grada Splita provedena je na temelju skupa podataka koji obuhvaća 12 parametara kvalitete vode određenih u uzorcima prikupljenim na 3 lokacije ispusta tijekom četverogodišnjeg perioda (2006. – 2009.).

Prije provođenja osnovne statističke analize, preliminarno je izrađena matrica podataka koja je uključivala grupiranje i transformiranje podataka. U fazi grupiranja, parametri čije su vrijednosti bile ispod granice detekcije ili kvantifikacije uklonjeni su iz analize. Također su uklonjeni skupovi podataka za koje nisu bili mjereni svi parametri za pojedino razdoblje. S obzirom da se ponekad nisu određivali svi parametri (razlog tome bili su uglavnom tehničke prirode, kvar na instrumentima) ukupna baza podataka po pojedinoj lokaciji nešto je manja od predviđene za svakodnevno mjerenja kroz 4 godine. Baza za daljnju analizu predstavljala je samo kompletne podatke rezultata analize za sve parametre na pojedinoj lokaciji. Sukladno tome baza za lokaciju 1 (Katalinića brig) sadržavala je 761 skup podataka od 12 parametara onečišćenja, baza podataka za lokaciju 2 (Duilovo) sadržavala je 735 skupova podataka za 12 parametara, a baza za lokaciju 3 (Stupe) 531 skup podataka.

Za provedbu svih analiza korištena je računalna podrška programskog sustava Statistika 10.0. Za opis pouzdanosti dobivenih rezultata poslužila je prethodno određena razina signifikantnosti rezultata, p . Vrijednost razine signifikantnosti p predstavlja mjeru za pouzdanost rezultata, i što je ona veća, manja je vjerojatnost da je opažena korelacija između varijabli u uzorku pouzdani pokazatelj njihove korelacije u stvarnom sustavu (ukupnoj populaciji). Razina signifikantnosti p može se onda objasniti kao vjerojatnost pogreške ukoliko dobiveni rezultat prihvatimo kao važeći, a pouzdanost rezultata zapravo je onda jednaka $1-p$. Odabrana razina signifikantnosti u svim provedenim statističkim analizama jest $p \leq 0,05$, što se inače smatra graničnom vrijednošću za pouzdanost rezultata. To zapravo znači da postoji 5% vjerojatnosti pogreške da je nađeni odnos između varijabli uistinu takav i u stvarnom sustavu.

U daljnjoj obradi eksperimentalnih podataka za sve je varijable prije provedbe multivarijantnih analiza provedena analiza normalnosti raspodjele Kolmogorov-Smirnov testom te je za varijable za koje nije utvrđena normalna raspodjela provedena normalizacija (logaritamska transformacija) i normalizacija prema jednadžbi:

$$D_i = relF_i - rel\hat{F}_i \quad (14)$$

gdje je D_i apsolutna razlika između promatranih i očekivanih frekvencija F .

3.3.2. Multivarijantna analiza za prostornu i vremensku klasifikaciju pokazatelja onečišćenja

U ovom radu provedena je klaster analiza (CA, od engl. *Cluster Analysis*) kako bi se utvrdile sličnosti odnosno razlike među ispitivanim lokacijama na temelju njihovog fizikalno-kemijskog sastava. Kako je cilj klaster analize grupirati slične objekte, prvi korak u provođenju ove analize je izbor mjerila sličnosti odnosno udaljenosti. Osnovna mjerila udaljenosti između pojedinih objekata su Euklidne udaljenosti (od engl. *Euclidean distances*), odnosno kvadrat Euklidne udaljenosti (od engl. *squared Euclidean distance*), koje se u načelu najčešće koriste u ovakvim analizama. Hijerarhijska klaster analiza u osnovi je iterativan proces spajanja objekata u grupe, a metodu karakterizira nepoznat broj klastera koji se utvrđuje na temelju dendrograma. Dendrogram je grafički prikaz postupnog kombiniranja objekata u klastere na kojem se uočavaju udaljenosti između pojedinih razina. Za razvoj klastera koristi se nekoliko metoda hijerarhijske klaster analize, a jedino se *Wardovom* metodom ne računa udaljenost između klastera, nego maksimizira homogenost unutar klastera. Mjerilo te homogenosti je suma kvadrata pogreške unutar klastera (ESS, od engl. *error sum of squares*). U ovom radu provedena je analiza za tri lokacije ispusta te za 4 godine uz 12 parametara onečišćenja. Korištena je Wardova metoda korištenjem kvadratnih Euklidnih udaljenosti te je napravljen dendrogram Euklidnih udaljenosti ($[Dlink/Dmax]*100$). Temeljem tako provedene analize dobiveni su dendrogrami za lokacije i za četverogodišnje razdoblje karakterizacije pokazatelja onečišćenja komunalnih otpadnih voda grada Splita.

3.3.3. Izrada multivarijabilnih linearnih modela

Kao osnova za izradu multivarijabilnih linearnih modela poslužila je korelacijska matrica pokazatelja onečišćenja po pojedinim lokacijama za ukupni promatrani period. Pearson-ov koeficijent korelacije i Spearman-ov rank koeficijent korelacije su korišteni kako bi se ispitala korelacija između pojedinih varijabli. Odabrana razina signifikantnosti u svim provedenim statističkim analizama jest $p \leq 0,05$, što se inače smatra graničnom vrijednošću za pouzdanost rezultata u industrijskim procesima. To označava mogućnost greške od 5 % da pronađeni odnos između varijabli nije reprezentativan na čitav osnovni skup. Kao mjera točnosti modela računat je i regresijski koeficijent, R^2 čije vrijednosti pomažu u međusobnoj usporedbi modela. On mjeri proporciju varijance zavisne varijable oko njezine srednje vrijednosti. Vrijednost regresijskog koeficijenta kreće se u granicama 0-1. Veći R^2 znači veću snagu modela u objašnjavanju regresijske funkcije i dakle bolju predikciju zavisne varijable. Promatran model je to reprezentativniji što je koeficijent regresije bliži jedinici, a koeficijent regresije računa se prema formuli:

$$R^2 = 1 - \frac{SSE}{SST} \quad (15)$$

$$SSE = \sum_{i=1}^n \left(y_i - \hat{y}_i \right)^2 \quad (16)$$

$$SST = SSE + SSR \quad (17)$$

$$SSR = \sum_{i=1}^n \left(\hat{y}_i - \bar{y} \right)^2 \quad (18)$$

gdje su:

SSE = "sum of squared errors"; suma kvadratnih odstupanja modelom predviđenih od pripadajućih eksperimentalno utvrđenih vrijednosti promatrane zavisne varijable y

SSR = "sum of squared residuals"; suma kvadratnih odstupanja modelom predviđenih vrijednosti od srednje vrijednosti eksperimentalno utvrđenih vrijednosti zavisne varijable y

SST = "total sum of squares"; ukupna suma svih kvadratnih odstupanja

\hat{y}_i = modelom predviđena vrijednost $\hat{y}_i = f(x_i)$

\bar{y} = srednja vrijednost eksperimentalno utvrđenih vrijednosti promatrane zavisne varijable y

3.3.3.1. Viševarijantni linearni model

Viševarijantni linearni model je algebarski model kojima se analitički određuje statistička povezanost jedne numeričke varijable s dvije ili više numeričkih varijabli:

$$y = f(x_1, x_2, x_3, \dots, x_n) \quad (19)$$

U navedenom modelu y je zavisna varijabla. Ona predstavlja pojavu čije se promjene odražavaju pomoću nezavisnih varijabli $x_1, x_2, x_3, \dots, x_n$.

Viševarijantni linearni model može poprimiti različite oblike. Izbor modela, odnosno njegova specifikacija, ovisi o zahtjevima konkretne primjene. Osnovni je model viševarijantna linearna regresija ("Multiple Linear Regression", MLR), koja ima oblik:

$$y = B_0 + B_1 \cdot x_1 + B_2 \cdot x_2 + \dots + B_n \cdot x_n \quad (20)$$


B_0 = odsječak na osi y

za normalizirani model

$$y = \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \dots + \beta_n \cdot x_n \quad (21)$$

Veza između zavisne varijable i odabranog skupa nezavisnih varijabli mora biti linearna kao što je opisano u jednadžbama.

Viševarijantni linearni model izrađen je kako bi odredili odnos između mjerenih varijabli, odnosno želimo istražiti linearnu zavisnost pokazatelja onečišćenja KPK i BPK₅ o skupu preostalih pokazatelja onečišćenja. Metoda koja će najvjernije to opisati jest viševarijantna linearna regresija, MLR. Ovom metodom analizira se međuzavisnost pojedinih varijabli (slika 15), a jačina korelacija varijabli opisuje se regresijskim koeficijentima β .



Slika 15. Prikaz jednostavne linearne aproksimacije nelinearne zavisnosti izlazne veličine (y) o pojedinoj ulaznoj veličini (x_i)

Ako se na dijagramu povuče pravac, on je općenito oblika:

$$y = \beta_0 + \beta_1 \cdot x \quad (22)$$

gdje je β_0 konstantan član tj. očekivana vrijednost zavisne varijable kada je nezavisna varijabla jednaka nuli.


Regresijski koeficijent β_1 pokazuje prosječnu promjenu zavisne varijable kada nezavisna varijabla poraste za jedinicu.

Regresijska analiza traži parametre β_0 , β_1 tako da pravac y prolazi između stvarnih točaka promatranih varijabli i da najbolje tumači vezu između njih, odnosno pravac mora biti takav da odstupanja budu najmanja. Postoji više različitih metoda za ocjenu ovih parametara, a najčešće korištena metoda je metoda najmanjih kvadrata. Odstupanja mogu biti pozitivna i negativna, da se ne bi međusobno poništile te pozitivne i negativne vrijednosti, ova metoda minimizira sumu kvadratnog odstupanja.

3.3.3.2. Model lokalne linearne regresije

Nelinearne funkcije, odnosno nelinearni procesi, često se mogu u pojedinim dijelovima aproksimirati linearnim funkcijama. Na taj način pojednostavljuje se model

procesa i olakšava izražavanje odabrane izlazne veličine. To u pravilu znači da odabrana izlazna veličina koja ukazuje na stanje sustava i opisuje proces, do svoje određene vrijednosti ("točka loma" ili "breakpoint") slijedi jednu linearnu funkciju, a zatim drugu (slika 16).



Slika 16. Opći grafički prikaz djelomične linearne regresije - nelinearna funkcija (označena crnom bojom), aproksimirana je linearnim funkcijama (pravci označeni crvenom, plavom, ljubičastom i zelenom bojom).

Nelinearnost procesa procijenjena je metodom lokalne linearne regresije ("Piecewise Linear Regression", PLR), a za uzastopnu minimalizaciju odstupanja modela od eksperimentalno utvrđenih vrijednosti primijenjena je približna Newtonova metoda (engl. quasi Newton method).

Na taj način određena je vrijednost KPK i BPK₅ a predstavlja točku loma (y_0), kao i parametri modela, B , koji ukazuju na jakost i prirodu utjecaja nezavisnih varijabli kako je prikazano općom jednadžbom modela:⁸¹

$$\begin{aligned} y \leq y_0; \quad y_1 &= B_{1,0} + B_{1,1} \cdot x_1 + B_{1,2} \cdot x_2 + \dots + B_{1,n} \cdot x_n \\ y \geq y_0; \quad y_2 &= B_{2,0} + B_{2,1} \cdot x_1 + B_{2,2} \cdot x_2 + \dots + B_{2,n} \cdot x_n \end{aligned} \quad (23)$$


gdje su:

y_0 = vrijednost odabrane izlazne veličine koja predstavlja točku loma

$B_{i,0}$ = odsječak na osi y linearne aproksimacijske funkcije y_i

3.3.4. Određivanje indeksa kvalitete komunalnih otpadnih voda grada Splita primjenom neizrazite logike

Za određivanje kvalitete vode korištena je metoda neizrazite logike (fuzzy logic). Modeliranjem nesigurnosti i postavljanjem neizrazitih skupova/neizrazitih brojeva i nesigurnosti kod dobivenih podataka o pokazateljima onečišćenja koji utječu na kvalitetu otpadnih voda, ovim postupkom je uobličena (normalizirana) u neizraziti broj. Konstrukcija broja ili fuzzy skupova za stručnu percepciju modeliranja u klasifikaciji svakog parametra u jezičnim izrazima kao što su: vrlo dobar, dobar, korektan i loš dopušta upućivanje na sve potrebne vrijednosti pokazatelja koje će biti opisani. Dobiveni podatci za određene pokazatelje onečišćenja izraženi su preko određivanja funkcija pripadnosti (*eng. membership function*), a za sve izračune korišten je programski sustav MATLAB. Za određivanje stupnja pripadnosti korištene su Gaussove krivulje. Postupak i slijed određivanja pojedinih funkcija pripadnosti shematski je prikazan na slici 17.



Slika 17. Shematski prikaz određivanja stupnja pripadnosti programskim sustavom MATLAB

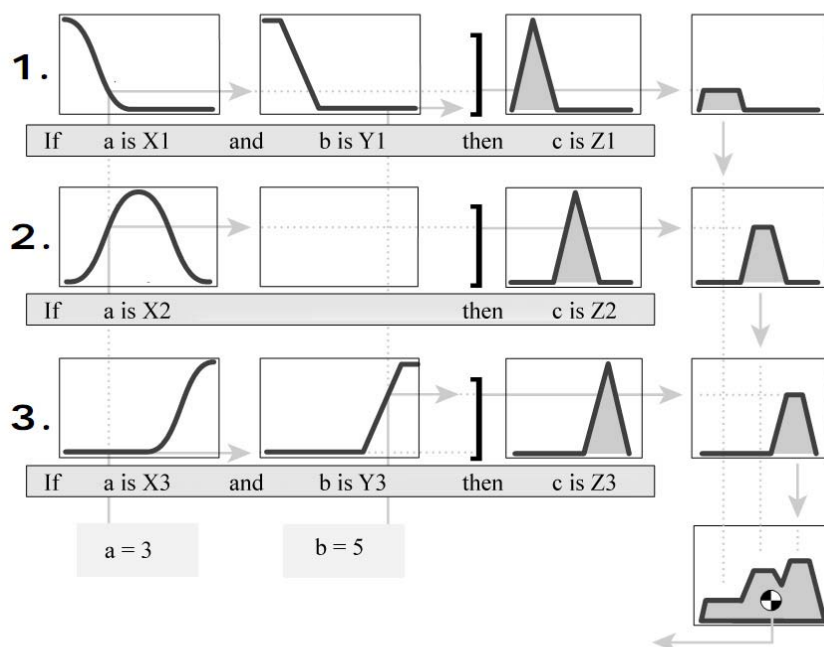
Za određivanje stupnjeva pripadnosti kao indeksa kvalitete vode prethodno su uz pomoć programskog sustava određena 42 (AKO- ONDA; engl. IF-THEN) pravila neizrazite logike:

1. **Ako** je pH „vrlo dobar“ i suspendirana tvar „dobar“ i BPK₅ ili KPK „dobar“ i ukupni fosfor ili ukupni dušik „dobar“ **onda** je status vode „**dobar**“.
2. **Ako** je pH „vrlo dobar“ i suspendirana tvar „korektan“ i BPK₅ ili KPK „korektan“ i ukupni dušik ili ukupni fosfor „dobar“ **onda** je status vode „**dobar**“.
3. **Ako** je pH „vrlo dobar“ i suspendirana tvar „korektan“ i BPK₅ ili KPK „korektan“ i ukupni dušik ili fosfor „korektan“ **onda** je status vode „**korektan**“.
4. **Ako** je pH „vrlo dobar“ i suspendirana tvar „korektan“ i BPK₅ ili KPK „dobar“ i ukupni dušik ili ukupni fosfor „dobar“ **onda** je status vode „**dobar**“.
5. **Ako** je pH „vrlo dobar“ i suspendirana tvar „korektna“ i BPK₅ ili KPK „dobar“ i ukupni dušik ili ukupni fosfor „korektan“ **onda** je status vode „**dobar**“.
6. **Ako** je pH „vrlo dobar“ i suspendirana tvar „loša“ i BPK₅ ili KPK „loš“ i ukupni fosfor ili ukupni dušik „korektan“ **onda** je status vode „**korektan**“.
7. **Ako** je pH „vrlo dobar“ i suspendirana tvar „korektna“ i BPK₅ „dobar“ i ukupni dušik ili ukupni fosfor „korektan“ **onda** je status vode „**dobar**“.
8. **Ako** je pH „vrlo dobar“ i suspendirana tvar „dobra“ i BPK₅ ili KPK „korektan“ i ukupni dušik ili ukupni fosfor „korektan“ **onda** je status vode „**dobar**“.
9. **Ako** je pH „vrlo dobar“ i suspendirana tvar „loša“ i BPK₅ ili KPK „korektan“ i ukupni dušik ili ukupni fosfor „korektan“ **onda** je status vode „**korektan**“.
10. **Ako** je pH „vrlo dobar“ i suspendirana tvar „loša“ i BPK₅ ili KPK „loš“ i ukupni dušik ili ukupni fosfor „loš“ **onda** je status vode „**loš**“.
11. **Ako** je pH „vrlo dobar“ i suspendirana tvar „loša“ i BPK₅ ili KPK „dobar“ i ukupni dušik ili ukupni fosfor „korektan“ **onda** je status vode „**korektan**“.
12. **Ako** je pH „vrlo dobar“ i suspendirana tvar „vrlo dobra“ i BPK₅ ili KPK „vrlo dobar“ i ukupni dušik ili ukupni fosfor „vrlo dobar“ **onda** je status vode „**vrlo dobar**“.
13. **Ako** je pH „vrlo dobar“ i suspendirana tvar „vrlo dobra“ i BPK₅ ili KPK „vrlo dobar“ i ukupni dušik ili ukupni fosfor „dobar“ **onda** je status vode „**vrlo dobar**“.
14. **Ako** je pH „vrlo dobar“ i suspendirana tvar „vrlo dobar“ i BPK₅ ili KPK „dobar“ i ukupni dušik ili ukupni fosfor „vrlo dobar“ **onda** je status vode „**vrlo dobar**“.

15. **Ako** je pH „vrlo dobar“ i suspendirana tvar „vrlo dobra“ i BPK₅ ili KPK „dobar“ i ukupni dušik ili ukupni fosfor „dobar“ **onda** je status vode „**vrlo dobar**“.
16. **Ako** je pH „vrlo dobar“ i suspendirana tvar „dobra“ i BPK₅ ili KPK „vrlo dobar“ i ukupni dušik ili ukupni fosfor „dobar“ **onda** je status vode „**vrlo dobar**“.
17. **Ako** je pH „vrlo dobar“ i suspendirana tvar „dobra“ i BPK₅ ili KPK „dobar“ i ukupni dušik ili ukupni fosfor „vrlo dobar“ **onda** je status vode „**vrlo dobar**“.
18. **Ako** je pH „dobar“ i suspendirana tvar „dobar“ i KPK ili BPK₅ „dobar“ i ukupni dušik ili ukupni fosfor „dobar“ **onda** je status vode „**dobar**“.
19. **Ako** je pH „dobar“ i suspendirana tvar „korektan“ i BPK₅ ili KPK „korektan“ i ukupni dušik ili ukupni fosfor „korektan“ **onda** je status vode „**korektan**“.
20. **Ako** je pH „dobar“ i „suspendirana tvar „loša“ i BPK₅ ili KPK „korektan“ i ukupni dušik ili ukupni fosfor „loš“ **onda** je status vode „**loš**“.
21. **Ako** je pH „dobar“ i suspendirana tvar „korektna“ i BPK₅ ili KPK „loš“ i ukupni dušik ili ukupni fosfor „loš“ **onda** je status vode „**loš**“.
22. **Ako** je pH „dobar“ i suspendirana tvar „dobra“ i BPK₅ ili KPK „korektan“ i ukupni dušik ili ukupni fosfor „korektan“ **onda** je status vode „**korektan**“.
23. **Ako** je pH „dobar“ i suspendirana tvar „loša“ i BPK₅ ili KPK „loš“ i ukupni fosfor ili ukupni dušik „korektan“ **onda** je status vode „**loš**“.
24. **Ako** je pH „dobar“ i suspendirana tvar „korektna“ i BPK₅ ili KPK „loš“ i ukupni dušik ili ukupni fosfor „loš“ **onda** je status vode „**loš**“.
25. **Ako** je pH „dobar“ i suspendirana tvar „korektna“ i BPK₅ ili KPK „dobar“ i ukupni dušik ili ukupni fosfor „dobar“ **onda** je status vode „**korektan**“.
26. **Ako** je pH „dobar“ i suspendirana tvar „loša“ i BPK₅ ili KPK „loš“ i ukupni dušik ili ukupni fosfor „loš“ **onda** je status vode „**loš**“.
27. **Ako** je pH „dobar“ i suspendirana tvar „loša“ i BPK₅ ili KPK „dobar“ i ukupni dušik ili ukupni fosfor „dobar“ **onda** je status vode „**korektan**“.
28. **Ako** je pH „korektan“ i suspendirana tvar „dobar“ i KPK ili BPK₅ „dobar“ i ukupni dušik ili ukupni fosfor „dobar“ **onda** je status vode „**dobar**“.
29. **Ako** je pH „korektan“ i suspendirana tvar „loša“ i BPK₅ ili KPK „loš“ i ukupni fosfor ili ukupni dušik „korektan“ **onda** je status vode „**loš**“.
30. **Ako** je pH „korektan“ i suspendirana tvar „korektna“ i BPK₅ ili KPK „korektan“ i ukupni dušik ili ukupni fosfor „korektan“ **onda** je status vode „**korektan**“.

31. **Ako** je pH „korektan“ i suspendirana tvar „korektna“ i BPK₅ ili KPK „dobar“ i ukupni dušik ili ukupni fosfor „korektan“ **onda** je status vode „**korektan**“.
32. **Ako** je pH „korektan“ i suspendirana tvar „korektna“ i BPK₅ ili KPK „dobar“ i ukupni dušik ili ukupni fosfor „dobar“ **onda** je status vode „**dobar**“.
33. **Ako** je pH „korektan“ i suspendirana tvar „dobra“ i BPK₅ ili KPK „dobar“ i ukupni dušik ili ukupni fosfor „korektan“ **onda** je status vode „**dobar**“.
34. **Ako** je pH „korektan“ i suspendirana tvar „dobra“ i BPK₅ ili KPK „korektan“ i ukupni dušik ili ukupni fosfor „dobar“ **onda** je status vode „**dobar**“.
35. **Ako** je pH „loš“ i suspendirana tvar „loša“ i BPK₅ ili KPK „korektan“ i ukupni dušik ili ukupni fosfor „korektan“ **onda** je status vode „**loš**“.
36. **Ako** je pH „loš“ i suspendirana tvar „korektna“ i BPK₅ ili KPK „korektan“ i ukupni dušik ili ukupni fosfor „loš“ **onda** je status vode „**loš**“.
37. **Ako** je pH „loš“ i suspendirana tvar „dobra“ i BPK₅ ili KPK „dobar“ i ukupni dušik ili ukupni fosfor „korektan“ **onda** je status vode „**korektan**“.
38. **Ako** je pH „loš“ i suspendirana tvar „korektna“ i BPK₅ ili KPK „korektan“ i ukupni dušik ili ukupni fosfor „korektan“ **onda** je status vode „**korektan**“.
39. **Ako** je pH „loš“ i suspendirana tvar „loša“ i BPK₅ ili KPK „loš“ i ukupni dušik ili ukupni fosfor „loš“ **onda** je status vode „**loš**“.
40. **Ako** je pH „loš“ i suspendirana tvar „loša“ i BPK₅ ili KPK „korektan“ i ukupni dušik ili ukupni fosfor „loš“ **onda** je status vode „**loš**“.
41. **Ako** je pH „loš“ i suspendirana tvar „korektna“ i BPK₅ ili KPK „dobar“ i ukupni dušik ili ukupni fosfor „dobar“ **onda** je status vode „**korektan**“.
42. **Ako** je pH „loš“ i suspendirana tvar „korektna“ i BPK₅ ili KPK „dobar“ i ukupni dušik ili ukupni fosfor „korektan“ **onda** je status vode „**korektan**“.

Pojednostavljen, općeniti primjer cijelog postupka donošenja zaključka temeljen na neizrazitoj logici prikazan je na slici 18.



Slika 18. Konačni Fuzzy dijagram za određivanje kvalitete vode

4. REZULTATI

U ovom radu provedena je karakterizacija pokazatelja onečišćenja otpadnih voda grada Splita na tri ispusta u periodu 4 godine. Na osnovi skupa podataka dobivenog svakodnevnim mjerenjem, provedena je osnovna statistička analiza mjerenih parametara (pokazatelja onečišćenja) određivanjem srednjih vrijednosti, standardne devijacije, varijance, medijana, min i max vrijednosti i koeficijenta varijacije za pojedine parametre na sve tri lokacije te multivarijantna analiza (faktorska analiza i analiza glavnih komponenata) koji su poslužili kao baza za izradu dva linearna modela najznačajnijih pokazatelja onečišćenja (KPK i BPK₅) na sve tri lokacije za period od 4 godine. Izrađen je multivarijabilni linearni regresijski model (MLR) i model lokalne linearne regresije (PLR). S obzirom na nelinearnost sustava obrade otpadne vode osim ovih linearnih modela uporabljena je i naprednija metoda modeliranja, metoda neizrazite (fuzzy) logike uz pomoć koje je postavljen indeks kakvoće otpadne vode na sve tri crpne stanice komunalne otpadne vode sa šireg područja grada Splita.

4.1. Osnovna statistička analiza pokazatelja onečišćenja komunalne otpadne vode grada Splita

Na osnovi skupa podataka dobivenih monitoringom pokazatelja onečišćenja komunalnih otpadnih voda grada Splita na lokacijama Katalinića brig (Lokacija 1), Duilovo (Lokacija 2) i Stupe (Lokacija 3), provedena je osnovna statistička analiza pokazatelja onečišćenja, a rezultati su prikazani u tablicama 9, 10 i 11.

Tablica 9. Osnovna statistička analiza pokazatelja onečišćenja na Lokaciji 1

Parametar	Osnovna statistika Lokacija 1 Katalinića brig							
	N	Sred.vrije	Medijan	Min	Max.	Varijanca	Std.Dev.	Koef.Var.
pH	761	7,8104	7,8600	6,43000	8,600	0,1	0,2846	3,644
Susp.tvar	760	213,9132	199,0000	23,00000	4247,000	35834,1	189,2990	88,493
KPK	761	365,7545	372,2000	87,53000	775,800	13860,7	117,7315	32,189
BPK ₅	761	172,3215	170,7700	47,80000	328,200	1570,3	39,6274	22,996
Cl ⁻	761	685,6075	416,8300	48,34000	5653,290	742753,4	861,8314	125,703
SO ₄ ²⁻	761	78,9757	72,0000	6,17000	888,800	2896,3	53,8173	68,144
O - P	761	5,9265	5,4800	1,00000	14,140	5,2	2,2722	38,340
N-NH ₄ ⁺	761	43,1537	41,3400	2,53000	120,600	350,5	18,7207	43,382
N-NO ₂ ⁻	761	0,0831	0,0760	0,00000	2,034	0,0	0,1074	129,245
N-NO ₃ ⁻	761	1,8960	1,3020	0,01800	10,740	2,9	1,7128	90,333
Deterg.	761	10,5627	3,7100	0,10000	5023,000	33106,9	181,9529	1722,593
Ukupni P	761	9,8314	9,3200	1,82000	24,520	12,4	3,5238	35,842

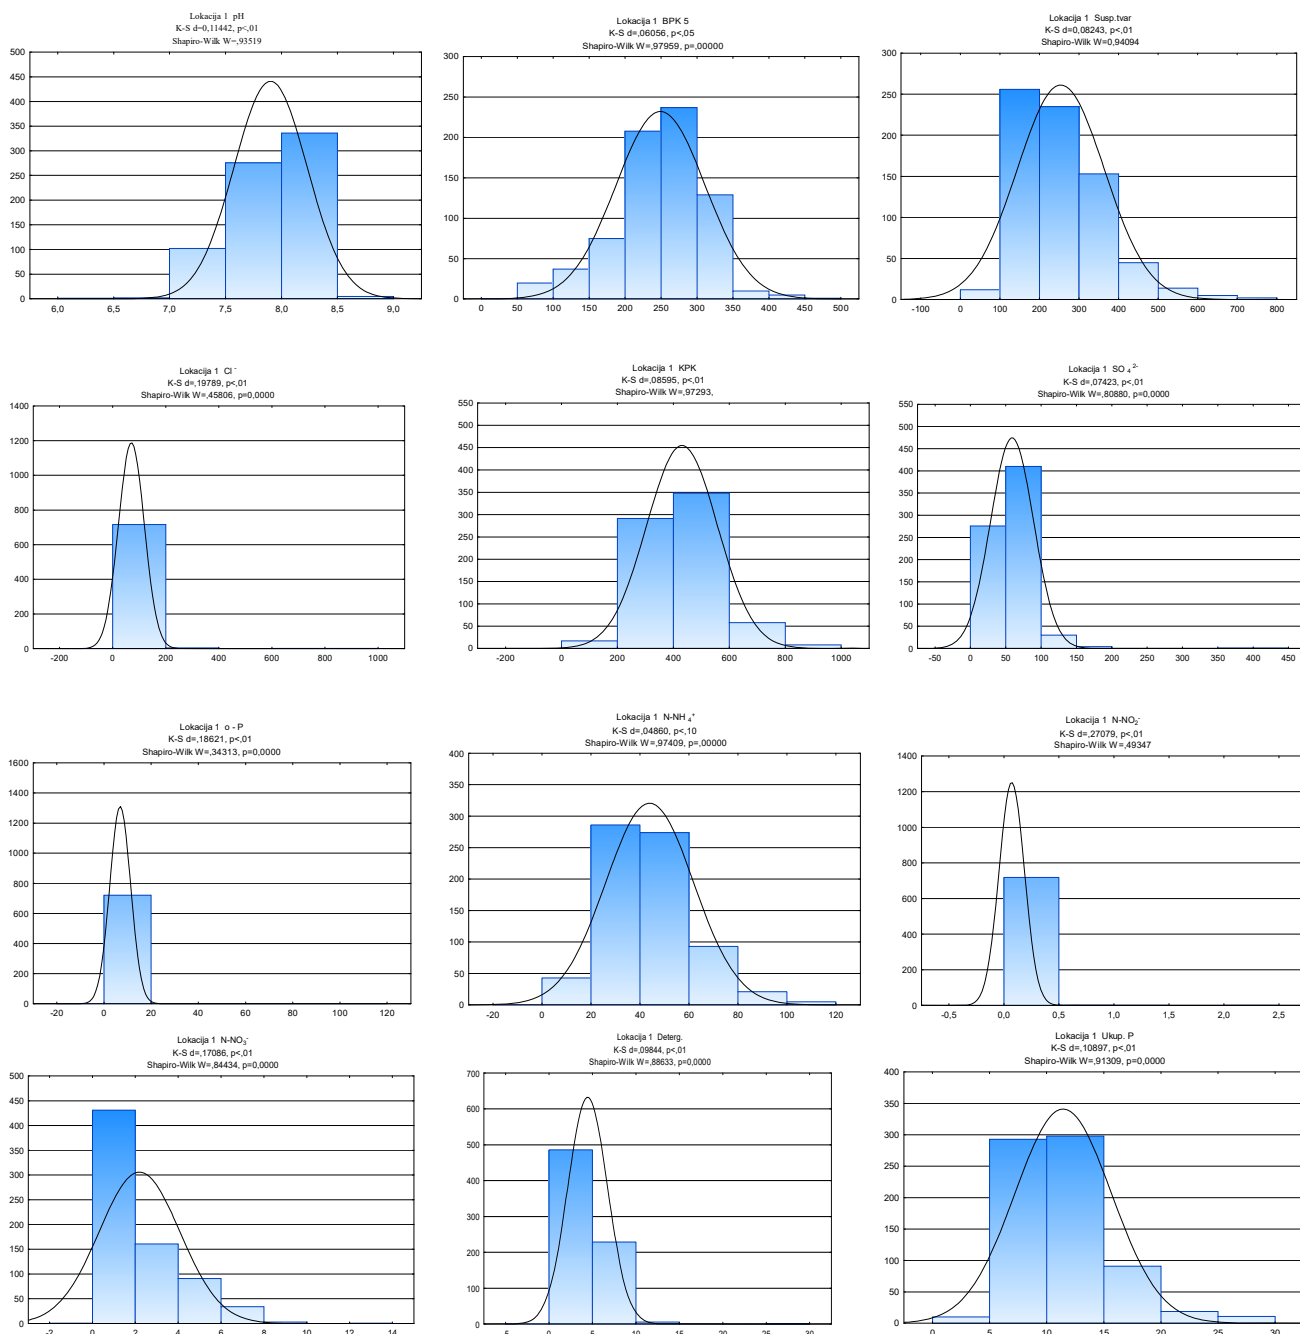
Tablica 10. Osnovna statistička analiza pokazatelja onečišćenja na Lokaciji 2

Parametar	Osnovna statistika Lokacija 2 Duilovo							
	N	Sred.vrije	Medijan	Min.	Max.	Varijanca	Std.Dev.	Koef.Var.
pH	735	7,9027	7,9900	6,37000	8,8100	0,11	0,3254	4,1174
Susp.tvar	735	256,3932	240,0000	33,00000	938,0000	12887,22	113,5219	44,2765
KPK	735	433,0763	419,5000	51,61000	919,6000	16485,31	128,3951	29,6472
BPK ₅	735	252,1182	255,4300	71,21000	672,7300	4759,78	68,9912	27,3646
Cl ⁻	735	70,2690	63,1800	6,53000	920,8000	2319,21	48,1582	68,5341
SO ₄ ²⁻	735	59,9762	56,9000	1,64000	772,0400	1615,14	40,1887	67,0078
O - P	735	6,8953	6,4700	0,61000	110,1300	19,06	4,3656	63,3131
N-NH ₄ ⁺	735	43,8115	42,2200	3,10000	109,2600	323,77	17,9937	41,0707
N-NO ₂ ⁻	735	0,0715	0,0570	0,00100	2,1580	0,01	0,1146	160,3340
N-NO ₃ ⁻	735	2,1753	1,4580	0,00000	12,2700	3,51	1,8737	86,1323
Deterg.	735	4,4581	4,0300	0,23000	27,1800	5,19	2,2776	51,0900
Ukup. P	735	11,4646	10,4800	3,33000	29,6800	17,85	4,2249	36,8518

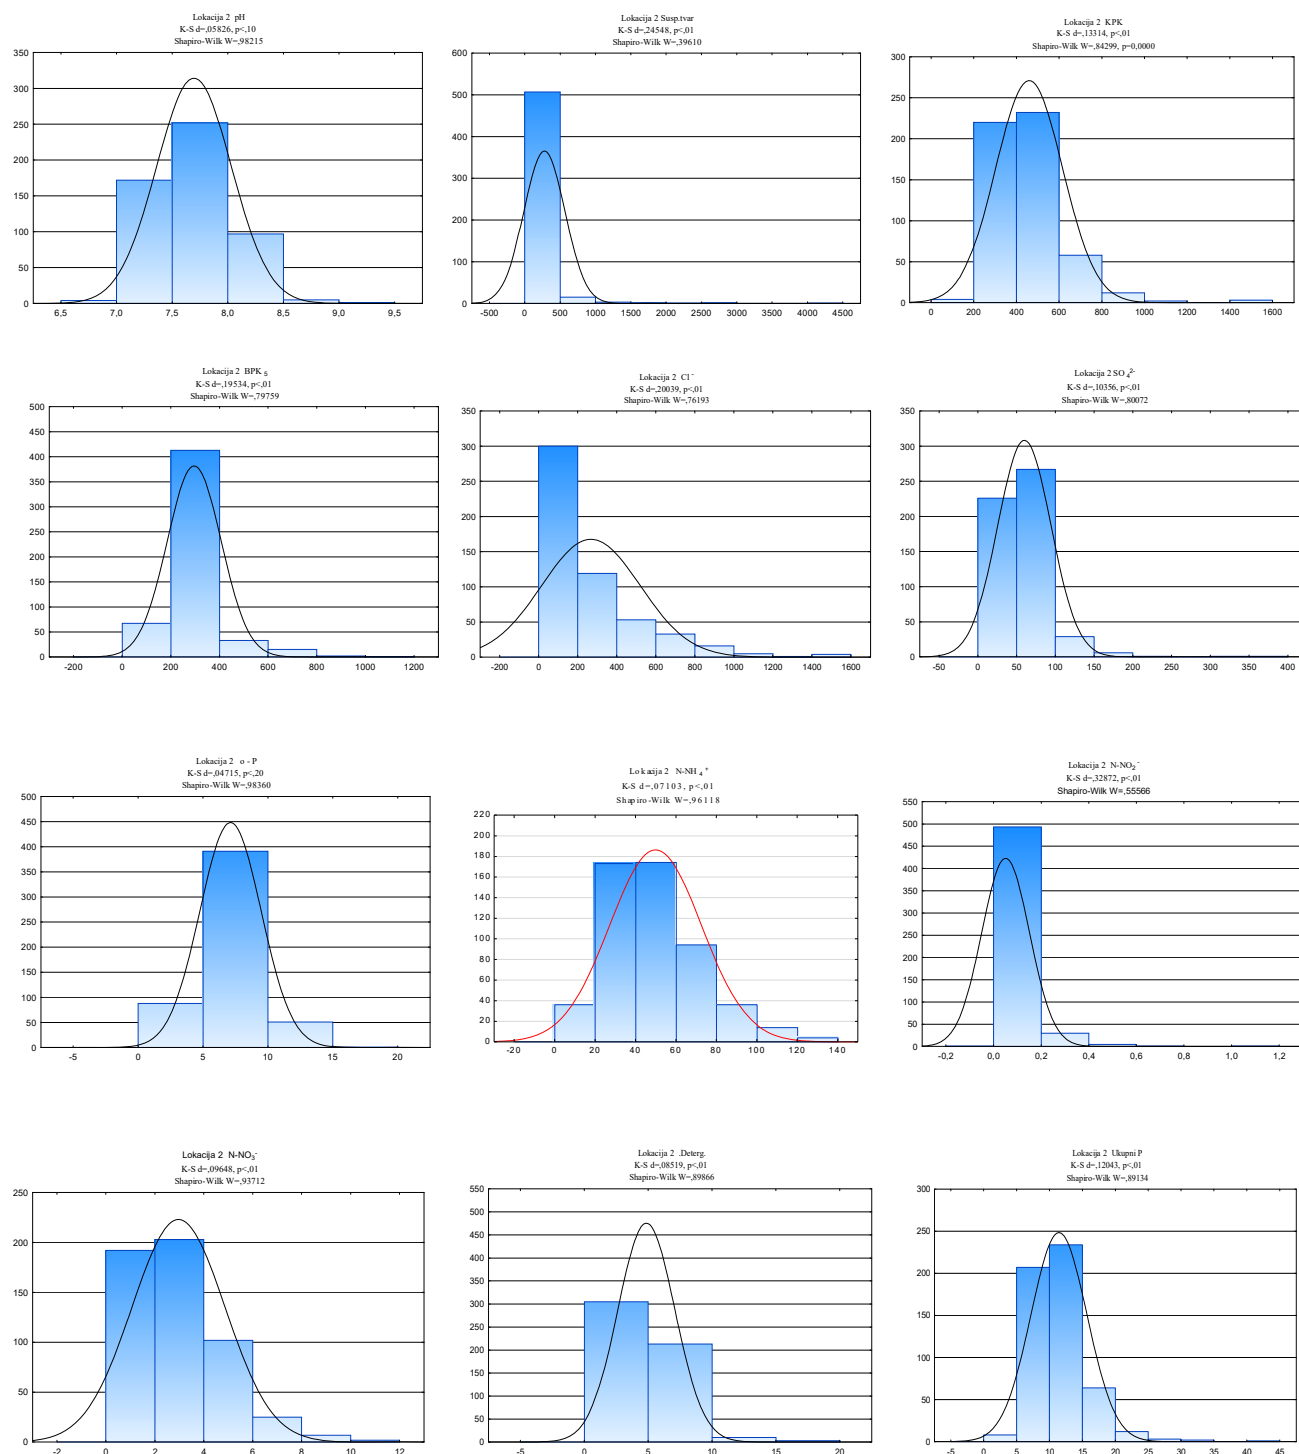
Tablica 11. Osnovna statistička analiza pokazatelja onečišćenja na Lokaciji 3

Parametar	Osnovna statistika Lokacija 3 Stupe							
	N	Sred.vrije	Medijan	Min.	Max.	Varijanca	Std.Dev.	Koef.Var.
pH	531	7,6964	7,6800	6,7700	9,210	0,11	0,3373	4,3823
Susp.tvar	531	278,4979	234,0000	28,0000	4150,000	84141,92	290,0723	104,1560
KPK	531	459,9471	416,4200	140,6000	1476,780	24441,05	156,3363	33,9901
BPK ₅	531	296,2648	281,7000	88,0000	1004,100	12318,42	110,9884	37,4626
Cl ⁻	531	268,0034	171,1700	6,3900	1597,040	63895,52	252,7756	94,3181
SO ₄ ²⁻	531	60,0760	55,7100	3,1700	357,650	1180,47	34,3580	57,1909
O - P	531	7,1217	7,0100	0,8400	18,050	5,58	2,3629	33,1790
N-NH ₄ ⁺	531	49,9339	46,4800	4,7800	122,710	516,95	22,7365	45,5333
N-NO ₂ ⁻	531	0,0508	0,0010	0,0000	1,010	0,01	0,1002	197,3644
N-NO ₃ ⁻	531	2,9667	2,5960	0,0010	11,350	3,61	1,9012	64,0837
Deterg.	531	4,8611	4,5800	0,2300	19,330	4,96	2,2266	45,8042
Ukupni P	531	11,4405	10,6500	1,5600	40,860	18,18	4,2635	37,2668

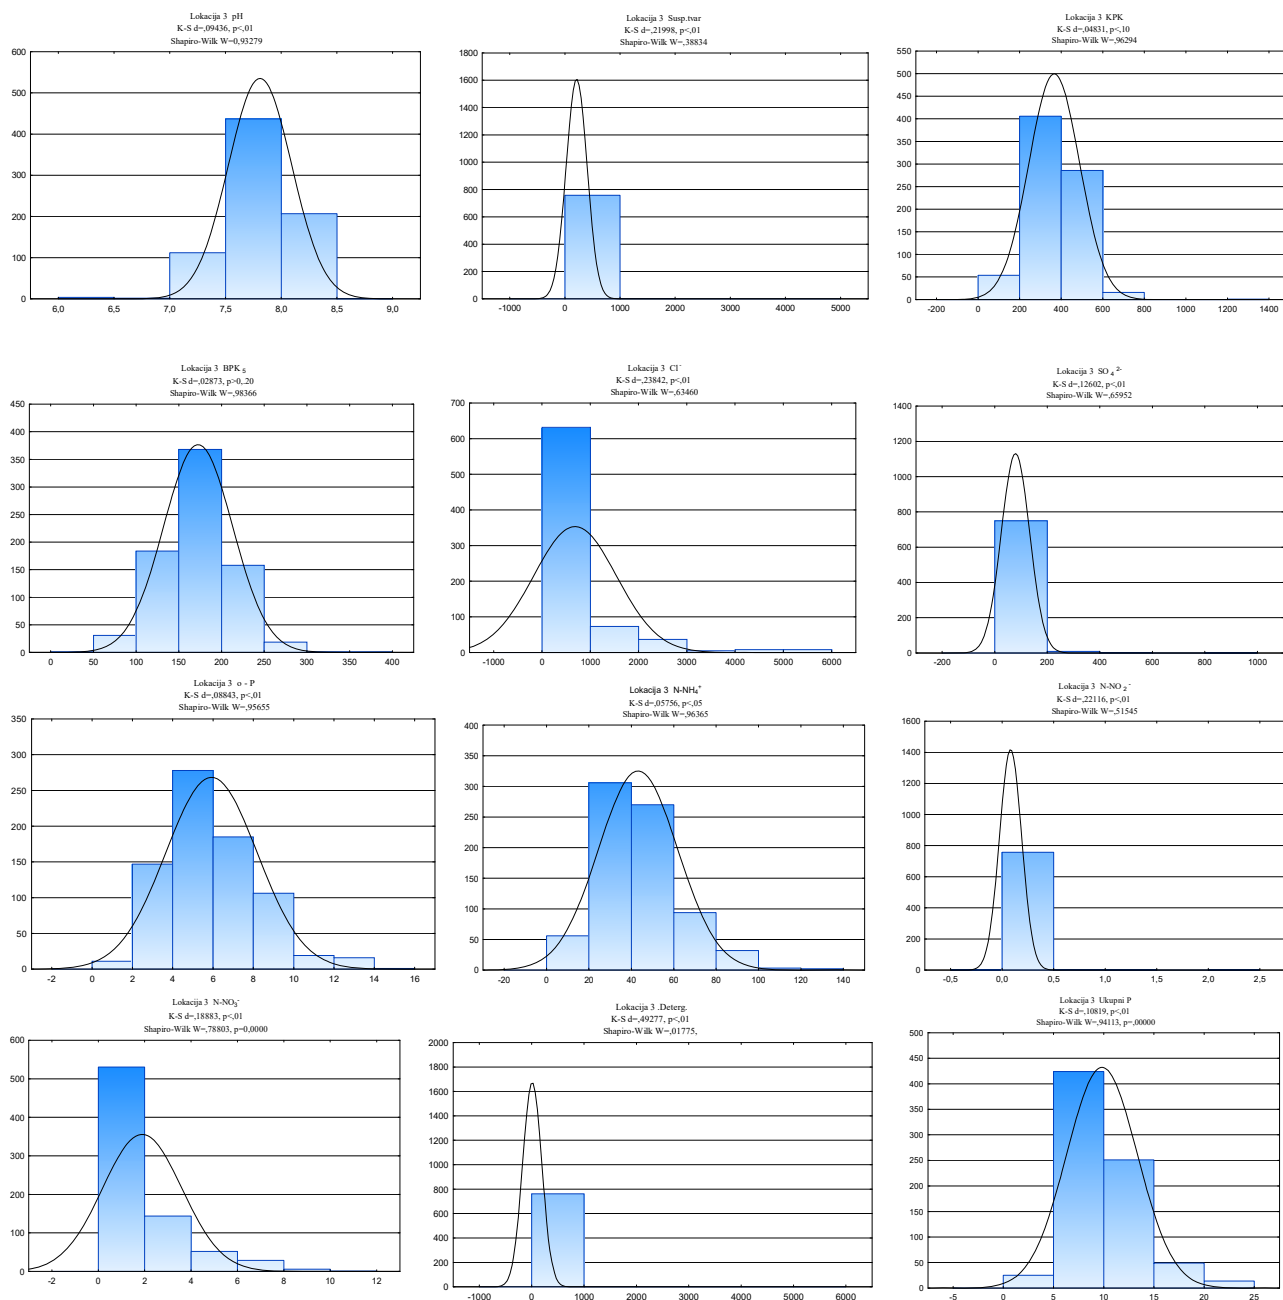
Osim navedenih vrijednosti proveden je i test normalnosti razdiobe pojedinih pokazatelja onečišćenja za sve tri lokacije, a dobiveni grafički prikazi vidljivi su na slikama 19, 20 i 21 gdje *os x* predstavlja dobivene eksperimentalne vrijednosti za pojedine parametre, a *os y* broj uzoraka za pojedine parametre.



Slika 19. Normalna razdioba za pojedine pokazatelje onečišćenja za Lokaciju 1




Slika 20. Normalna razdioba za pojedine pokazatelje onečišćenja za Lokaciju 2




Slika 21. Normalna razdioba za pojedine pokazatelje onečišćenja za Lokaciju 3.


Na osnovi dobivenih vrijednosti koeficijenata spljoštenosti i zakrivljenosti krivulja za većinu parametara vidljivo je odstupanje od normalne razdiobe, te je isti postupak ponovljen za logaritmirane podatke pokazatelja onečišćenja. Rezultati određivanja koeficijenata zakrivljenosti i spljoštenosti za oba skupa podataka za tri promatrane lokacije prikazani su na slikama 22, 23 i 24.



Slika 22. Koeficijenti zakrivljenosti i spljoštenosti krivulja raspodjele za izvorne i log transformirane podatke za Lokaciju 1




Slika 23. Koeficijenti zakrivljenosti i spljoštenosti krivulja raspodjele za izvorne i log transformirane podatke za Lokaciju 2




Slika 24. Koeficijenti zakrivljenosti i spljoštenosti krivulja raspodjele za izvorne i log transformirane podatke za Lokaciju 3

4.2. Prostorna i vremenska klasifikacija pokazatelja onečišćenja komunalnih otpadnih voda grada Splita


Kako bi se utvrdila prostorna i vremenska raspodjeljenost parametara provedena je multivarijantna analiza pokazatelja onečišćenja preko faktorske analize i analize glavnih komponenata. Prije provedbe analiza svi podaci su normalizirani kako bi se eliminirao utjecaj različitih mjernih jedinica za pojedine parametre.




Slika 25. Prikaz pojedinih pokazatelja onečišćenja prema faktorima 1 i 2 za Lokaciju 1



Slika 26. Prikaz pojedinih pokazatelja onečišćenja prema faktorima 1 i 2 za Lokaciju 2




Slika 27. Prikaz pojedinih pokazatelja onečišćenja prema faktorima 1 i 2 za Lokaciju 3




Slika 28. Analiza glavnih komponenteata za sve tri lokacije


Za otkrivanje prostorne sličnosti pri grupiranju uzoraka s promatranih lokacija, primjenjena je prostorna klaster analiza koja je producirala dendrogram s jednom grupom za Lokacije 2 i 3 kod $(D_{link}/D_{max}) \times 100 < 45$ koji je prikazan na slici 29.




Slika 29. Dendrogram klaster analize prema Ward-u za prostorno grupiranje prema lokacijama



Slika 30. Dendrogram klaster analize prema Ward-u za grupiranje prema godinama za Lokaciju 1



Slika 31. Dendrogram klaster analize prema Ward-u za grupiranje prema godinama za Lokaciju 2



Slika 32. Dendrogram klaster analize prema Ward-u za grupiranje prema godinama za Lokaciju 3

4.3. Viševarijantni linearni modeli pokazatelja onečišćenja komunalnih otpadnih voda grada Splita

Nakon provedene osnovne statističke analize sa svrhom što egzaktnije usporedbe i utvrđivanja trendova kretanja i međuzavisnosti pojedinih pokazatelja onečišćenja prevedeno je međusobno koreliranje pokazatelja kako bi se što bolje opisao međusobni odnos pokazatelja onečišćenja u otpadnoj vodi po pojedinim lokacijama za razdoblje od 4 godine. Rezultati korelacijskih matrica dobivenih prema Pearsonovim korelacijskim koeficijentima prikazani su u tablicama 12, 13, i 14.

Tablica 12. Korelacijska matrica pokazatelja onečišćenja za Lokaciju 1

Korelacijska matrica pokazatelja onečišćenja za lokaciju 1.										
Parametar	pH	Susp.tvar	KPK	BPK ₅	Cl ⁻	SO ₄ ²⁻	O - P	N-NH ₄ ⁺	N-NO ₂ ⁻	N-NO ₃ ⁻
pH	1,000000	0,004830	0,017827	-0,010337	-0,161118	-0,018919	-0,035320	0,011021	0,032206	-0,182708
Susp.tvar	0,004830	1,000000	-0,050029	-0,066491	-0,006820	-0,030588	0,021367	-0,045680	-0,012663	0,164427
KPK	0,017827	-0,050029	1,000000	0,278599	0,196201	-0,048441	0,070889	0,233744	-0,089166	0,282609
BPK ₅	-0,010337	-0,066491	0,278599	1,000000	0,038193	-0,062673	0,019200	0,169229	-0,069891	0,085392
Cl ⁻	-0,161118	-0,006820	0,196201	0,038193	1,000000	0,174012	0,084198	0,102420	-0,036477	0,176491
SO ₄ ²⁻	-0,018919	-0,030588	-0,048441	-0,062673	0,174012	1,000000	-0,005830	-0,105731	0,033535	-0,045372
O - P	-0,035320	0,021367	0,070889	0,019200	0,084198	-0,005830	1,000000	0,215543	-0,081921	0,133211
N-NH ₄ ⁺	0,011021	-0,045680	0,233744	0,169229	0,102420	-0,105731	0,215543	1,000000	-0,096303	0,178903
N-NO ₂ ⁻	0,032206	-0,012663	-0,089166	-0,069891	-0,036477	0,033535	-0,081921	-0,096303	1,000000	-0,037699
N-NO ₃ ⁻	-0,182708	0,164427	0,282609	0,085392	0,176491	-0,045372	0,133211	0,178903	-0,037699	1,000000
Deterg.	0,012247	-0,009239	0,009028	-0,001080	-0,012275	-0,024842	-0,030680	0,016341	-0,028441	-0,016548
Ukupni P	0,054117	-0,042081	0,089871	0,019991	0,042895	0,120481	0,564646	0,067633	-0,047755	0,090166


Tablica 13. Korelacijska matrica pokazatelja onečišćenja za Lokaciju 2

Korelacijska matrica pokazatelja onečišćenja za lokaciju 2.										
Parametar	pH	Susp.tvar	KPK	BPK ₅	Cl ⁻	SO ₄ ²⁻	O - P	N-NH ₄ ⁺	N-NO ₂ ⁻	N-NO ₃ ⁻
pH	1,000000	0,233293	0,002396	-0,130988	-0,015499	-0,004275	0,027735	-0,075642	0,127612	-0,184247
Susp.tvar	0,233293	1,000000	0,040211	0,030736	0,021624	-0,024733	0,006272	-0,188292	0,169141	-0,269732
KPK	0,002396	0,040211	1,000000	0,183669	0,016283	0,003039	0,036556	0,076821	-0,030198	0,034645
BPK ₅	-0,130988	0,030736	0,183669	1,000000	-0,011805	-0,011240	0,005621	0,068996	-0,084490	0,027364
Cl ⁻	-0,015499	0,021624	0,016283	-0,011805	1,000000	-0,003713	0,052442	0,109166	-0,033938	0,106198
SO ₄ ²⁻	-0,004275	-0,024733	0,003039	-0,011240	-0,003713	1,000000	0,001502	0,002585	0,029940	0,056568
O - P	0,027735	0,006272	0,036556	0,005621	0,052442	0,001502	1,000000	0,148996	-0,020230	0,069109
N-NH ₄ ⁺	-0,075642	-0,188292	0,076821	0,068996	0,109166	0,002585	0,148996	1,000000	-0,088637	0,275034
N-NO ₂ ⁻	0,127612	0,169141	-0,030198	-0,084490	-0,033938	0,029940	-0,020230	-0,088637	1,000000	-0,150722
N-NO ₃ ⁻	-0,184247	-0,269732	0,034645	0,027364	0,106198	0,056568	0,069109	0,275034	-0,150722	1,000000
Deterg.	0,025052	-0,009835	0,141464	0,111991	0,147643	0,009151	0,013443	0,189013	-0,071041	0,211625
Ukup. P	0,052993	0,013426	-0,017844	-0,020477	0,029292	0,043150	0,378863	0,110480	0,101856	0,169437


Tablica 14. Korelacijska matrica pokazatelja onečišćenja za Lokaciju 3

Parametar	Korelacijska matrica pokazatelja onečišćenja za lokaciju 3								
	pH	Susp.tvar	KPK	BPK 5	Cl ⁻	SO ₄ ²⁻	O - P	N-NH ₄ ⁺	N-NO ₂ ⁻
pH	1,000000	0,026275	-0,031233	-0,022082	0,019863	-0,050614	0,009480	0,113390	0,008468
Susp.tvar	0,026275	1,000000	0,077305	0,058613	-0,016168	-0,036542	0,095918	-0,025709	0,040498
KPK	-0,031233	0,077305	1,000000	0,473554	-0,037272	-0,086752	0,099568	-0,085267	0,048822
BPK 5	-0,022082	0,058613	0,473554	1,000000	-0,046500	-0,130373	0,090168	-0,127993	0,036120
Cl ⁻	0,019863	-0,016168	-0,037272	-0,046500	1,000000	0,251589	-0,062762	0,056391	0,049644
SO ₄ ²⁻	-0,050614	-0,036542	-0,086752	-0,130373	0,251589	1,000000	0,023476	0,045759	-0,080144
O - P	0,009480	0,095918	0,099568	0,090168	-0,062762	0,023476	1,000000	0,116556	-0,023486
N-NH ₄ ⁺	0,113390	-0,025709	-0,085267	-0,127993	0,056391	0,045759	0,116556	1,000000	-0,073895
N-NO ₂ ⁻	0,008468	0,040498	0,048822	0,036120	0,049644	-0,080144	-0,023486	-0,073895	1,000000
N-NO ₃ ⁻	0,083949	-0,114801	-0,132236	-0,168367	0,211291	0,166246	-0,090457	0,211215	-0,054916
Deterg.	0,095064	-0,077760	-0,124073	-0,078853	0,025791	0,068199	0,038611	0,170870	-0,014010
Ukupni P	0,074574	0,002594	0,011944	0,046654	0,149968	-0,003196	0,429732	0,198429	0,124558


Linearna multivarijantna analiza provedena je, za glavne pokazatelje onečišćenja KPK i BPK₅ uz različit broj varijabli, izradom viševarijantnog linearnog modela (MLR) i modela lokalne linearne regresije (PLR). Kao zavisne varijable u modelima odabrani su parametri KPK i BPK₅ a ako nezavisne varijable u modele su uključeni svi ostali mjereni parametri. Nazavisne varijable u modelima postepeno su isključivane na osnovi korelacijske matrice, te su za najbolje slaganje odabrani modeli s 9 nezavisnih varijabli. Rezultati slaganja pojedinih modela s eksperimentalno određenim vrijednostima KPK i BPK₅ prikazani su na slikama 33 – 36 za Lokaciju 1, slikama 37-40 za Lokaciju 2 te slikama 41-44 za Lokaciju 3.




Slika 33. MLR model za KPK s 9 nezavisnih varijabli za Lokaciju 1




Slika 34. PLR model za KPK s 9 nezavisnih varijabli za Lokaciju 1




Slika 35. MLR model za BPK₅ s 9 nezavisnih varijabli za Lokaciju 1




Slika 36. PLR model za BPK₅ s 9 nezavisnih varijabli na Lokaciji 1




Slika 37. MLR model za KPK s 9 nezavisnih varijabli za Lokaciju 2




Slika 38. PLR model za KPK s 9 nezavisnih varijabli za Lokaciju 2




Slika 39. MLR model za BPK₅ s 9 nezavisnih varijabli za Lokaciju 2




Slika 40. PLR model za BPK₅ s 9 nezavisnih varijabli za Lokaciju 2




Slika 41. MLR model za KPK s 9 nezavisnih varijabli za Lokaciju 3



Slika 42. PLR model za KPK s 9 nezavisnih varijabli za Lokaciju 3



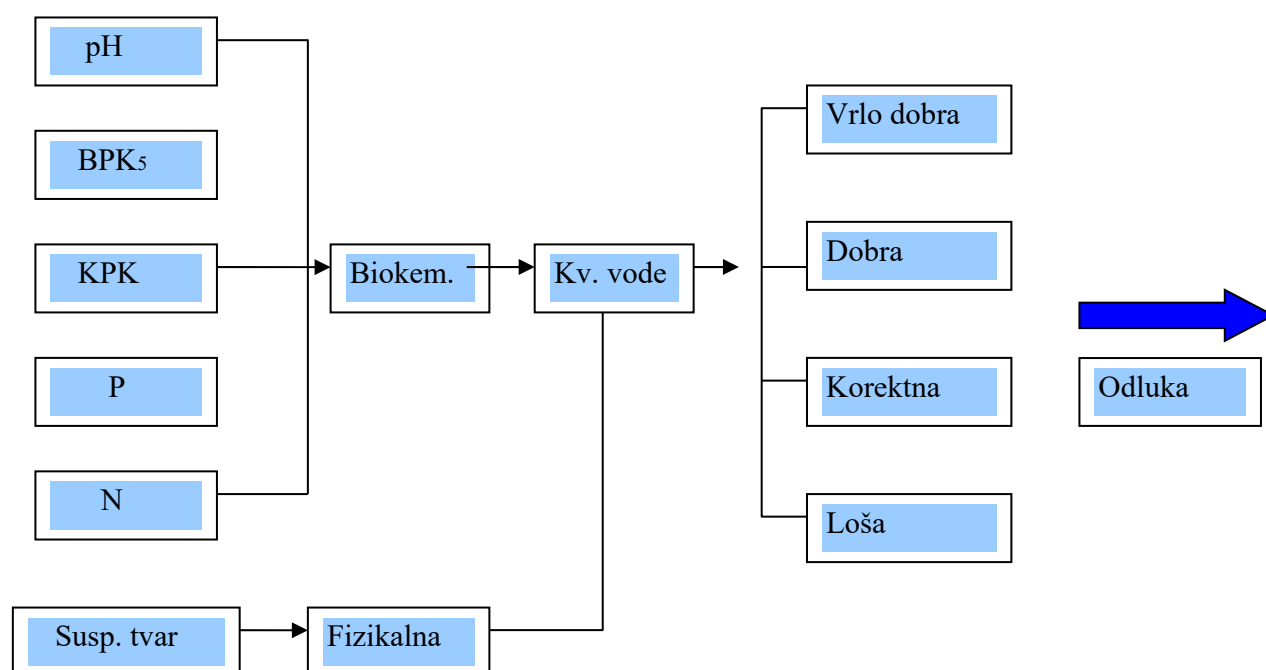
Slika 43. MLR model za BPK₅ s 9 nezavisnih varijabli za Lokaciju 3



Slika 44. PLR model za BPK₅ s 9 nezavisnih varijabli za Lokaciju 3

4.4. Određivanje indeksa kvalitete komunalnih otpadnih voda grada Splita primjenom neizrazite logike

Indeks kvalitete komunalne otpadne vode grada Splita određen je primjenom neizrazite logike. Kao baza poslužila je prethodno provedena statistička analiza mjerenih parametara na sve tri lokacije. Odabrano je 6 pokazatelja onečišćenja na sve tri lokacije i na osnovi njih je prema literaturi⁸² postavljena hijerarhijska struktura za klasifikaciju vode koja je prikazana na slici 45.



Slika 45. Hijerarhijska struktura za klasifikaciju vode

Prosječne vrijednosti tijekom godine, odnosno prema godišnjim dobima, za 6 ispitivanih parametara na tri različite lokacije prikazane su u tablicama 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25 i 26.

Tablica 15. Kvaliteta vode prema različitim parametrima koristeći neizrazitu logiku za godišnje doba “zima” (Lokacija 1)

2006.						2007.				
Kv. P	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode
pH	1.00	0.00	0.00	0.00	Vrlo dobar	1.00	0.00	0.00	0.00	Vrlo dobar
BPK ₅	0.00	0.95	0.00	0.00	Dobar	0.00	0.87	0.00	0.00	Dobar
KPK	0.00	0.51	0.34	0.00	Dobar	0.00	0.08	0.57	0.00	Korekt.
N _{uk}	0.00	0.00	0.30	0.39	Loš	0.00	0.00	0.00	0.87	Loš
P _{uk}	0.00	0.50	0.08	0.04	Dobar	0.00	0.38	0.06	0.03	Dobar
Susp. tvari	0.00	0.00	0.00	1.00	Loš	0.00	0.00	0.28	0.21	Korekt.
Ukupna kvaliteta vode					Dobra	Ukupna kvaliteta vode				Dobra

Tablica 16. Kvaliteta vode prema različitim parametrima koristeći neizrazitu logiku za godišnje doba “proljeće” (Lokacija 1)

2006.						2007.				
Kv. P	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode
pH	1.00	0.00	0.00	0.00	Vrlo dobar	1.00	0.00	0.00	0.00	Vrlo dobar
BPK ₅	0.00	0.98	0.00	0.00	Dobar	0.00	0.96	0.00	0.00	Dobar
KPK	0.00	0.73	0.29	0.00	Dobar	0.00	0.08	0.55	0.00	Korekt.
N _{uk}	0.00	0.00	0.62	0.05	Korekt.	0.00	0.00	0.00	1.00	Loš
P _{uk}	0.00	0.17	0.42	0.05	Korekt.	0.00	0.90	0.00	0.00	Dobar
Susp. tvari	0.00	0.23	0.14	0.00	Dobar	0.00	0.00	0.58	0.06	Korekt.
Ukupna kvaliteta vode					Dobra	Ukupna kvaliteta vode				Dobra

Tablica 17. Kvaliteta vode prema različitim parametrima koristeći neizrazitu logiku za godišnje doba “ljetno” (Lokacija 1)

2006.						2007.				
Kv. P	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode
pH	1.00	0.00	0.00	0.00	Vrlo dobar	1.00	0.00	0.00	0.00	Vrlo dobar
BPK ₅	0.00	0.95	0.00	0.00	Dobar	0.00	0.90	0.00	0.00	Dobar
KPK	0.00	0.92	0.25	0.00	Dobar	0.00	0.26	0.43	0.00	Fair
N _{uk}	0.00	0.00	0.02	0.77	Loš	0.00	0.00	0.00	1.00	Loš
P _{uk}	0.00	0.20	0.32	0.05	Korekt.	0.00	0.29	0.11	0.04	Dobar
Susp. tvari	0.00	0.22	0.15	0.00	Dobar	0.00	0.00	0.99	0.01	Korekt.
Ukupna kvaliteta vode					Dobra	Ukupna kvaliteta vode				Dobra

Tablica 18. Kvaliteta vode prema različitim parametrima koristeći neizrazitu logiku za godišnje doba “jesen” (Lokacija 1)

2006.						2007.				
Kv. P	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode
pH	1.00	0.00	0.00	0.00	Vrlo dobar	1.00	0.00	0.00	0.00	Vrlo dobar
BPK ₅	0.00	0.99	0.00	0.00	Dobar	0.00	0.91	0.00	0.00	Dobar
KPK	0.00	0.10	0.53	0.00	Korekt.	0.00	0.00	0.80	0.00	Korekt.
N _{uk}	0.00	0.00	0.75	0.18	Korekt.	0.00	0.00	0.00	1.00	Poor
P _{uk}	0.00	0.64	0.00	0.02	Dobar	0.00	0.54	0.02	0.04	Dobar
Susp. tvari	0.00	0.00	0.82	0.00	Korekt.	0.00	0.02	0.76	0.00	Korekt.
Ukupna kvaliteta vode					Dobra	Ukupna kvaliteta vode				Dobra

Tablica 19. Kvaliteta vode prema različitim parametrima koristeći neizrazitu logiku za godišnje doba “zima” (Lokacija 2)

2006.						2007.				
Kv. P	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode
pH	1.00	0.00	0.00	0.00	Vrlo dobar	1.00	0.00	0.00	0.00	Vrlo dobar
BPK ₅	0.02	0.80	0.00	0.00	Dobar	0.00	0.10	0.63	0.02	Korekt.
KPK	0.00	0.04	0.58	0.00	Korekt.	0.00	0.00	0.98	0.01	Korekt.
N _{uk}	0.00	0.00	0.40	0.32	Korekt.	0.00	0.00	0.00	0.90	Loš
P _{uk}	0.00	0.00	0.37	0.30	Korekt.	0.00	0.10	0.90	0.10	Korekt.
Susp. tvari	0.00	0.00	0.00	1.00	Loš	0.00	0.00	0.00	1.00	Loš
Ukupna kvaliteta vode					Korekt.	Ukupna kvaliteta vode				Korekt.

Tablica 20. Kvaliteta vode prema različitim parametrima koristeći neizrazitu logiku za godišnje doba “proljeće” (Lokacija 2)

2006.						2007.				
Kv. P	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode
pH	1.00	0.00	0.00	0.00	Vrlo dobar	1.00	0.00	0.00	0.00	Vrlo dobar
BPK ₅	0.00	0.91	0.00	0.00	Dobar	0.00	0.22	0.18	0.00	Dobar
KPK	0.00	0.05	0.56	0.00	Korekt.	0.00	0.03	0.73	0.00	Korekt.
N _{uk}	0.00	0.00	0.04	0.75	Loš	0.00	0.00	0.00	1.00	Loš
P _{uk}	0.00	0.15	0.53	0.07	Korekt.	0.00	0.18	0.28	0.05	Korekt.
Susp. tvari	0.00	0.00	0.87	0.00	Korekt.	0.00	0.00	0.00	1.00	Loš
Ukupna kvaliteta vode					Korekt.	Ukupna kvaliteta vode				Korekt.

Tablica 21. Kvaliteta vode prema različitim parametrima koristeći neizrazitu logiku za godišnje doba “ljetno” (Lokacija 2)

2006.						2007.				
Kv. P	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode
pH	1.00	0.00	0.00	0.00	Vrlo dobar	1.00	0.00	0.00	0.00	Vrlo dobar
BPK ₅	0.00	0.15	0.31	0.00	Korekt.	0.00	0.17	0.29	0.00	Korekt.
KPK	0.00	0.01	0.90	0.00	Korekt.	0.00	0.00	0.98	0.02	Korekt.
N _{uk}	0.00	0.00	0.05	0.55	Loš	0.00	0.00	0.00	1.00	Loš
P _{uk}	0.00	0.15	0.46	0.05	Korekt.	0.00	0.23	0.17	0.04	Dobar
Susp. tvari	0.00	0.00	0.81	0.05	Korekt.	0.00	0.00	0.02	0.95	Loš
Ukupna kvaliteta vode					Korekt.	Ukupna kvaliteta vode				Korekt.

Tablica 22. Kvaliteta vode prema različitim parametrima koristeći neizrazitu logiku za godišnje doba “jesen” (Lokacija 2)

2006.						2007.				
Kv. P	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode
pH	1.00	0.00	0.00	0.00	Vrlo dobar	1.00	0.00	0.00	0.00	Vrlo dobar
BOD ₅	0.00	0.09	0.60	0.02	Korekt.	0.00	0.30	0.08	0.00	Good
COD	0.00	0.00	0.95	0.01	Korekt.	0.00	0.00	0.90	0.00	Korekt.
N _{tot}	0.00	0.00	0.40	0.32	Korekt.	0.00	0.00	0.00	1.00	Loš
P _{tot}	0.00	0.02	0.98	0.16	Korekt.	0.00	0.25	0.17	0.05	Good
Susp. Solids	0.00	0.00	0.00	1.00	Loš	0.00	0.00	0.01	1.00	Loš
Ukupna kvaliteta vode					Korekt.	Ukupna kvaliteta vode				Korekt

Tablica 23. Kvaliteta vode prema različitim parametrima koristeći neizrazitu logiku za godišnje doba “zima” (Lokacija 3)

2006.						2007.				
Kv. P	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode
pH	1.00	0.00	0.00	0.00	Vrlo dobar	1.00	0.00	0.00	0.00	Vrlo dobar
BPK ₅	0.00	0.02	0.90	0.12	Korekt.	0.00	0.00	0.00	1.00	Loš
KPK	0.00	0.00	0.99	0.04	Korekt.	0.00	0.00	0.71	0.53	Korekt.
N _{uk}	0.00	0.00	0.62	0.05	Korekt.	0.00	0.00	0.00	0.87	Loš
P _{uk}	0.00	0.33	0.08	0.03	Dobar	0.00	0.20	0.37	0.05	Korekt.
Susp. tvari	0.00	0.00	0.00	1.00	Loš	0.00	0.00	0.06	0.56	Loš
Ukupna kvaliteta vode					Korekt.	Ukupna kvaliteta vode				Korekt.

Tablica 24. Kvaliteta vode prema različitim parametrima koristeći neizrazitu logiku za godišnje doba “proljeće” (Lokacija 3)

2006.						2007.				
Kv. P	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode
pH	1.00	0.00	0.00	0.00	Vrlo dobar	1.00	0.00	0.00	0.00	Vrlo dobar
BPK ₅	0.00	0.00	0.07	0.82	Loš	0.00	0.13	0.60	0.02	Korekt.
KPK	0.00	0.00	0.79	0.43	Korekt.	0.00	0.02	0.76	0.00	Korekt.
N _{uk}	0.00	0.00	0.00	0.90	Loš	0.00	0.00	0.00	1.00	Loš
P _{uk}	0.00	0.07	0.96	0.08	Korekt.	0.00	0.03	0.92	0.19	Korekt.
Susp. tvari	0.00	0.00	0.93	0.04	Korekt.	0.00	0.00	0.03	0.86	Loš
Ukupna kvaliteta vode					Korekt.	Ukupna kvaliteta vode				Korekt.

Tablica 25. Kvaliteta vode prema različitim parametrima koristeći neizrazitu logiku za godišnje doba “ljetno” (Lokacija 3)

2006.						2007.				
Kv. P	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode
pH	1.00	0.00	0.00	0.00	Vrlo dobar	1.00	0.00	0.00	0.00	Vrlo dobar
BPK ₅	0.00	0.00	0.00	1.00	Loš	0.00	0.02	0.94	0.14	Korekt.
KPK	0.00	0.00	0.70	0.58	Korekt.	0.00	0.00	0.98	0.02	Korekt.
N _{uk}	0.00	0.00	0.00	0.87	Loš	0.00	0.00	0.00	1.00	Loš
P _{uk}	0.00	0.05	0.95	0.15	Korekt.	0.00	0.19	0.37	0.04	Korekt.
Susp. tvari	0.00	0.00	0.00	1.00	Loš	0.00	0.00	0.02	0.94	Loš
Ukupna kvaliteta vode					Korekt.	Ukupna kvaliteta vode				Korekt.

Tablica 26. Kvaliteta vode prema različitim parametrima koristeći neizrazitu logiku za godišnje doba “jesen” (Lokacija 3)


2006.						2007.				
Kv. P	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode	Vrlo dobar	Dobar	Korekt.	Loš	Kval. vode
pH	1.00	0.00	0.00	0.00	Vrlo dobar	1.00	0.00	0.00	0.00	Vrlo dobar
BPK ₅	0.00	0.00	0.00	1.00	Loš	0.00	0.15	0.30	0.00	Korekt.
KPK	0.00	0.00	0.72	0.56	Korekt.	0.00	0.00	0.86	0.00	Korekt.
N _{uk}	0.00	0.00	0.60	0.22	Korekt.	0.00	0.00	0.00	1.00	Loš
P _{uk}	0.00	0.02	0.93	0.19	Korekt.	0.00	0.08	0.88	0.08	Korekt.
Susp. tvari	0.00	0.00	0.02	0.94	Loš	0.00	0.00	0.00	1.00	Loš
Ukupna kvaliteta vode					Korekt.	Ukupna kvaliteta vode				Korekt.

Prosječne vrijednosti za odabrane parametre na lokacijama 1, 2 i 3 za razdoblje 2006-2007 prikazane su u Tablici 27.

Tablica 27. Srednje godišnje vrijednosti \pm standardne devijacije parametara uključenih u analizu.


Parametar	Lokacija 1		Lokacija 2		Lokacija 3	
	2006	2007	2006	2007	2006	2007
pH	7.80 \pm 2.23	7.83 \pm 0.23	7.94 \pm 0.27	8.04 \pm 0.28	7.67 \pm 0.28	7.55 \pm 0.27
Suspend. tvari (mg/L)	222.32 \pm 150.46	215.31 \pm 91.05	263.33 \pm 189.37	314.80 \pm 107.05	363.19 \pm 146.27	288.24 \pm 110.42
KPK (mg O ₂ /L)	284.76 \pm 106.24	360.37 \pm 112.02	392.08 \pm 141.97	445.41 \pm 147.43	577.98 \pm 218.41	495.70 \pm 218.17
BPK ₅ (mg O ₂ /L)	155.68 \pm 38.97	172.26 \pm 42	226.96 \pm 87.90	251.77 \pm 72.51	389.77 \pm 109.67	317.83 \pm 131.06
P _{uk} (mg/L)	10.00 \pm 4.13	9.07 \pm 1.79	11.51 \pm 2.18	10.69 \pm 1.77	10.92 \pm 2.32	11.21 \pm 1.75
N _{uk} (mg/L)	33.33 \pm 13.45	44.44 \pm 17.73	32.89 \pm 12.19	44.96 \pm 17.21	32.86 \pm 14.16	45.70 \pm 17.98

Provedena je analiza međusobnih odnosa pojedinih varijabli i na slici 46 prikazan je jedan primjer odnosa ulaznih veličina KPK i BPK₅ u zadanom sustavu.




Slika 46. Primjer odnosa ulaznih podataka KPK i BPK₅


Provedbom analize neizrazite logike dobivene su funkcije pripadnosti za sve parametre na tri lokacije za period 2006. i 2007. godine. Primjer funkcija pripadnosti za određene vrijednosti parametara prikazane su na slikama 47, 48, 49, 50, 51 i 52.




Slika 47. Stupanj pripadnosti iz podataka za BPK₅ s jezičnim terminom „dobar“




Slika 48. Stupanj pripadnosti iz podataka za KPK s jezičnim terminom „korektan“




Slika 49. Stupanj pripadnosti iz podataka za N s jezičnim terminom „korektan“



Slika 50 . Stupanj pripadnosti iz podataka za pH s jezičnim terminom „vrlo dobar“



Slika 51. Stupanj pripadnosti iz podataka za BPK₅ s jezičnim terminom „korektan“



Slika 52. Stupanj pripadnosti iz podataka za ST s jezičnim terminom „korektan“

Na osnovi dobivenih funkcija pripadnosti za sve parametre određena je kvaliteta vode prema pojedinim parametrima na sve tri lokacije a rezultati su prikazani u tablicama 28 – 30.

Tablica 28. Kvaliteta vode prema različitim parametrima opisana neizrazitom logikom
(Lokacija 1)

2006.						2007.					
Kv. P	vrlo dobra	dobra	korek.	loša	kvalit. vode	vrlo dobra	dobra	korek.	loša	kvalit. vode	
pH	1.00	0.00	0.00	0.00	vrlo dobra	1.00	0.00	0.00	0.00	vrlo dobra	
BPK ₅	0.00	0.97	0.00	0.00	dobra	0.00	0.91	0.00	0.00	dobra	
KPK	0.00	0.39	0.37	0.00	korek.	0.00	0.08	0.61	0.00	korek.	
N _{uk}	0.00	0.00	0.12	0.55	loša	0.00	0.00	0.19	0.46	loša	
P _{uk}	0.00	0.28	0.11	0.04	dobra	0.00	0.52	0.03	0.03	dobra	
susp. tvari	0.00	0.00	0.71	0.03	korek.	0.00	0.00	0.75	0.02	korek.	
Ukupna kvaliteta vode					dobra	Ukupna kvaliteta vode					dobra

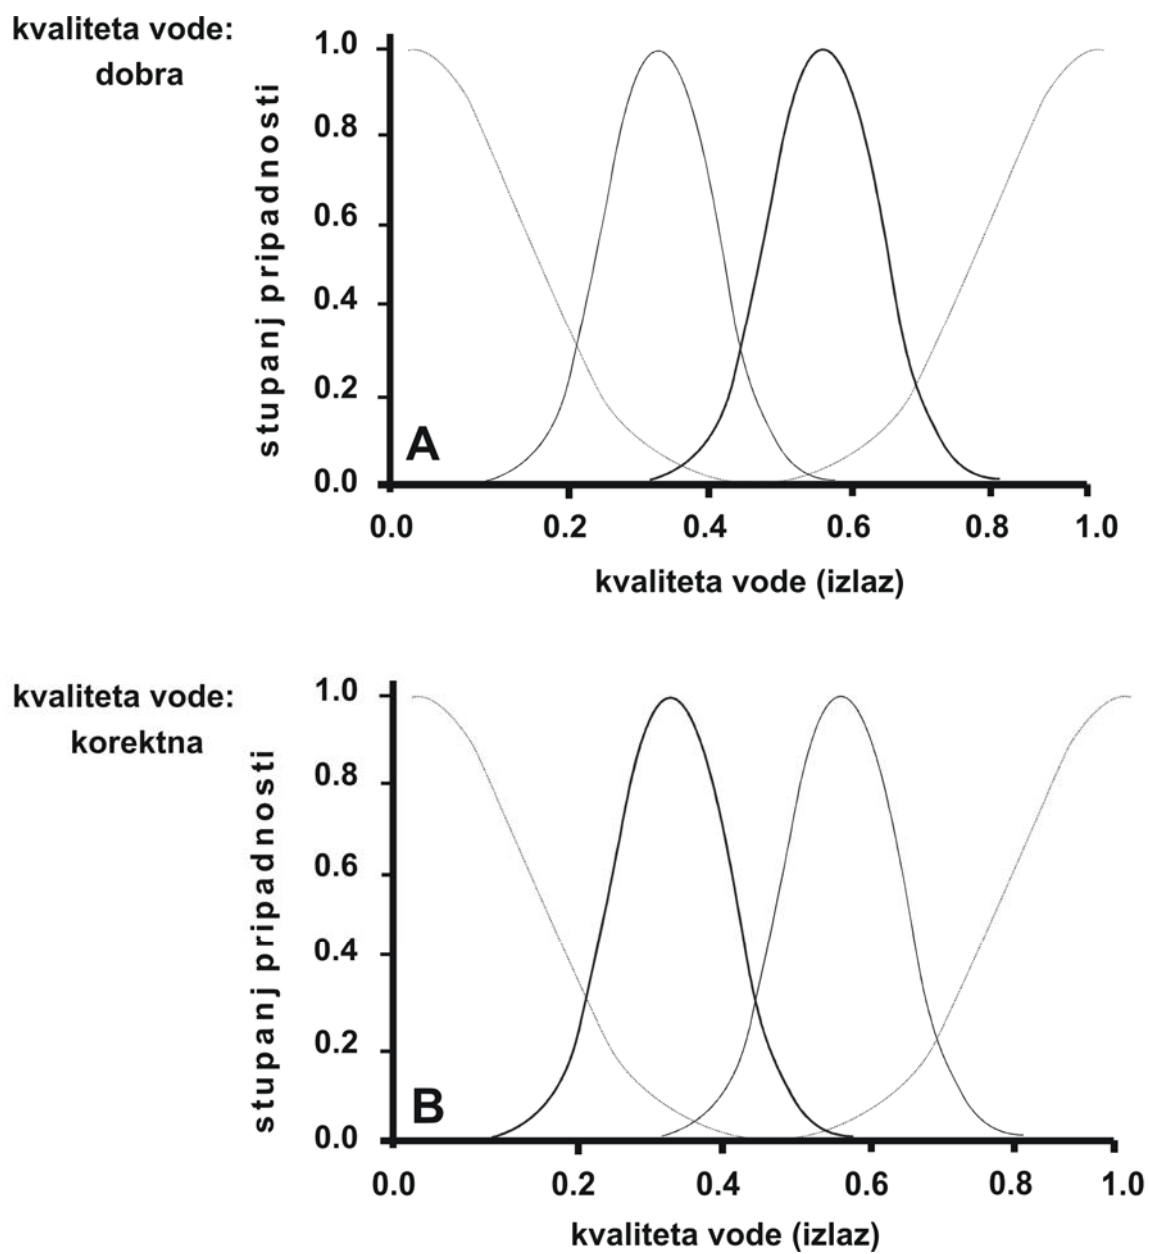
Tablica 29 . Kvaliteta vode prema različitim parametrima opisana neizrazitom logikom
(Lokacija 2)

2006.						2007.				
Kv. P	vrlo dobra	dobra	korek.	loša	kvalit. vode	vrlo dobra	dobra	korek.	loša	kvalit. vode
pH	1.00	0.00	0.00	0.00	vrlo dobra	1.00	0.00	0.00	0.00	vrlo dobra
BPK ₅	0.00	0.38	0.05	0.00	dobra	0.00	0.19	0.22	0.00	korek.
KPK	0.00	0.01	0.78	0.00	korek.	0.00	0.00	0.93	0.01	korek.
N _{uk}	0.00	0.00	0.14	0.52	loša	0.00	0.00	0.00	1.00	loša
P _{uk}	0.00	0.08	0.72	0.10	korek.	0.00	0.21	0.48	0.05	korek.
Susp. tvari	0.00	0.00	0.09	0.48	loša	0.00	0.00	0.00	1.00	loša
Ukupna kvaliteta vode					korek.	Ukupna kvaliteta vode				korek.

Tablica 30. Kvaliteta vode prema različitim parametrima opisana neizrazitom logikom
(Lokacija 3)

Kv. P	2006.					2007.				
	vrlo dobra	dobra	korek.	loša	kvalit. vode	vrlo dobra	dobra	korek.	loša	kvalit. vode
pH	1.00	0.00	0.00	0.00	vrlo dobra	1.00	0.00	0.00	0.00	vrlo dobra
BPK ₅	0.00	0.00	0.01	0.93	dobra	0.00	0.02	0.63	0.21	korek.
KPK	0.00	0.00	0.91	0.15	korek.	0.00	0.00	0.98	0.02	korek.
N _{uk}	0.00	0.00	0.15	0.51	loša	0.00	0.00	0.00	1.00	loša
P _{uk}	0.00	0.16	0.51	0.06	korek.	0.00	0.14	0.49	0.08	korek.
Susp. tvari	0.00	0.00	0.00	1.00	loša	0.00	0.00	0.02	0.93	loša
Ukupna kvaliteta vode					korek.	Ukupna kvaliteta vode				

Uzimajući u obzir dobivene rezultate provedena je analiza ukupne kvalitete vode na osnovi funkcija pripadnosti prikazanih na slici 53.



Slika 53. Primjer određivanja kvalitete vode: a) kvalitete vode - dobra (Lokacija 1);
b) kvaliteta vode – korektna (Lokacija 2 i 3)

Ukupni rezultati opisa kvalitete vode prema zadanim jezičnim pravilima sa stupnjevima pripadnosti prikazani su u tablici 31.

Tablica 31. Neizraziti opis kvalitete vode sa stupnjem pripadnosti za sve lokacije

2006.				2007.			
Kv. vode opis	Stupanj pripadnosti			Kv. vode opis	Stupanj pripadnosti		
	Lok. 1	Lok. 2	Lok. 3		Lok. 1	Lok. 2	Lok. 3
vrlo dobra	0.004	0.000	0.000	vrlo dobra	0.014	0.000	0.000
dobra	0.476	0.000	0.015	dobra	0.875	0.001	0.000
korek.	0.174	0.351	0.981	korek.	0.036	0.831	0.778
loša	0.004	0.237	0.046	loša	0.001	0.111	0.123

5. RASPRAVA

Sustavno praćenje vrijednosti pokazatelja onečišćenja komunalnih otpadnih voda zakonom je propisano i obveza je određenog vodnog subjekta. Dobiveni rezultati mogu poslužiti i kao vrijedna spoznaja o kakvoći otpadne vode koja se ispušta u određeni (prirodni) recipijent, a statistička obrada dobivenih podataka kao i modeliranje procesa nužan je korak u svakoj preliminarnoj studiji koja ima za cilj optimiranje i/ili unapređenje vođenja procesa pročišćavanja otpadne vode na pojedinom području. Informacija o statusu i promjenjivim trendovima u kvaliteti okoliša moraju biti dostupne javnosti te su neophodne za učinkovitiju implementaciju programa sprječavanja onečišćenja okoliša. U tom kontekstu zahtjevi za kvalitetom čistoće vode imaju važnu ulogu, te je zbog toga važno kontinuirano mjerenje pokazatelja onečišćenja u otpadne vode iz sustava odvodnje.

U ovom radu provedena je karakterizacija pokazatelja onečišćenja otpadnih voda grada Splita prikupljenih od strane ovlaštenog laboratorija za provedbu analiza. Karakterizacija je provedena na osnovi statističke analize, prostorne i vremenske multivarijantne analize pokazatelja onečišćenja na tri ispusta u periodu 4 godine. Izrađeni su i multivarijabilni linearni modeli (MLR i PLR) s 9 varijabli za najznačajnije pokazatelje onečišćenja izražene kao KPK i BPK₅ vrijednost komunalne otpadne vode na sve tri lokacije. Pokazana je nelinearnost i izrazita dinamičnost sustava te je nadalje uz pomoć neizrazite logike i grupiranja pokazatelja onečišćenja određen indeks kakvoće vode za sve tri lokacije.

Uzorci otpadne vode prikupljeni su svakodnevno na tri već opisane lokacije, nakon prethodne (primarne) obrade koja je obuhvaćala uklanjanja krupnih mehaničkih nečistoća na gruboj i finoj rešetki. Daljnja provedba standardnih analiza prema pravilniku o ispitivanju otpadnih voda⁸⁰ obavljena je u Laboratoriju javnog komunalnog poduzeća „Vodovod i kanalizacija“ Split.

Na osnovi baze podataka koja je sadržavala set četverogodišnjih mjerenja 12 parametara koji predstavljaju pokazatelje onečišćenja provedena je ranije opisana statistička i multivarijabilna analiza te je to, uz određivanje indeksa kakvoće vode, bila zadaća ove disertacije.

5.1. Osnovna statistička analiza pokazatelja onečišćenja komunalne otpadne vode grada Splita

Provedena statistička analiza mjerenih parametara pokazatelja onečišćenja komunalnih otpadnih voda grada Splita koji se ulijevaju u more Bračkog kanala dakle, prirodnog recipijenta pokazala je izrazitu nestalnost sastava. Provedba ovih analiza obvezan je postupak u preliminarnoj studiji za odabir tehnologije pročišćavanja i izradu projekta nadogradnje postojećeg sustava, te je preduvjet za postavljanje složenijih matematičkih modela koji će omogućiti što učinkovitiju kontrolu i optimizaciju procesa zbrinjavanja i obrade otpadne vode.

Statistička analiza uključivala je određivanje srednjih vrijednosti, standardnih devijacija, medijana, min i max vrijednosti, varijance i koeficijenta varijabilnosti svih pokazatelja onečišćenja na pojedinoj lokaciji, a rezultati su predstavljeni u tablicama 9, 10, i 11. S obzirom da se ponekad nisu određivali svi parametri (razlog tome bili su uglavnom tehničke prirode, kvar na instrumentima) ukupna baza podataka po pojedinoj lokaciji nešto je manja od predviđene za svakodnevno mjerenja kroz 4 godine. Baza za daljnju analizu predstavljala je samo kompletne podatke rezultata analize za sve parametre na pojedinoj lokaciji. Sukladno tome baza za Lokaciju 1 (Katalinića brig) sadržavala je 761 skup podataka od 12 parametara onečišćenja, baza podataka za Lokaciju 2 (Duilovo) sadržavala je 735 skupova podataka za 12 parametara, a baza za Lokaciju 3 (Stupe) 531 skup podataka.

Izrazito visoke vrijednosti za pojedine pokazatelje onečišćenja posebice koncentracije klorida i sulfata koje upućuju na eventualno prodiranja morske vode u sustav vidljive su na sve tri lokacije. Dokaz da se radi o uzorcima izrazito nehomogenog sastava daju dobivene vrijednosti koncentracije ukupnih suspendiranih tvari, koje su u slučaju homogenizacije uzorka prije provođenja analize, za red veličine veće od onih kada se određivanje vršilo bez prethodne homogenizacije. Time se mogu objasniti i akcidentni slučajevi kada koncentracije ukupnih suspendiranih tvari dostižu i do 5938 mg/L, a MDK za TSS iznosi 200 mg/L. Također i vrijednosti KPK nekoliko puta prelaze vrijednosti od 1000, pa čak dosežu i 3830,0 mg/L, a MDK za KPK iznosi 500 mg O₂/L. Razlozi navedenih fluktuacija mogu se objasniti i samim geografskim položajem grada Splita te klimatskim uvjetima odnosno rijetkim, ali obilnim kišama koje pridonose prikupljanju i transportu suspendiranih čestica do samih ispusta.

Sve eksperimentalne vrijednosti KPK su više u odnosu na vrijednosti BPK₅, jer kemijsko oksidacijsko sredstvo reagira s tvarima koje se ne razlažu djelovanjem mikrobne populacije, kao što su anorganske tvari, ili se vrlo sporo razlažu kao celuloza. Na povišenim temperaturama reakcije koje uključuju određivanje KPK traju samo 10 minuta i kroz taj period se razgradi i do 80% od ukupnog sadržaja organskih tvari. Ipak, BPK₅ je jedan od najčešće korištenih pokazatelja organskog onečišćenja. Organske tvari koje se razgrađuju mikrobiološkim procesima predstavljaju neposrednu opasnost za more kao recipijent, jer se procesima oksidacije iscrpljuje sadržaj kisika. Inače se procesi razgradnje u otpadnoj vodi počinju odvijati već u kanalizacijskom sustavu. Ove pojave vidljive su također i na ostalim sustavima za prikupljanje i pročišćavanje komunalnih otpadnih voda.

Median vrijednosti za sva onečišćenja bile su niže od njihove srednje vrijednosti, osim za biokemijsku potrošnju kisika (BPK₅) i pH vrijednosti na Lokaciji 2 te kemijsku potrošnju kisika (KPK) na Lokacijama 1 i 3.

Koeficijenti varijacije su sasvim drugačiji, s najvišim vrijednostima za nitritni dušik (N-NO_2^-) na Lokacijama 2 i 3, te koncentraciju deterdženata na Lokaciji 1. Najviši koeficijenti varijacije na Lokaciji 2 su dobiveni za ST , Cl^- , SO_4^{2-} , O-P i N-NO_3^- , na lokaciji 3 za ST i Cl^- te na Lokaciji 1 za ST , Cl^- , SO_4^{2-} , N-NO_2^- i N-NO_3^- . Ovo se može objasniti nedostatkom kompozitnih dnevnih uzoraka otpadne vode jer uzorak za analizu je uziman svakodnevno iz kanalizacijskog sustava za prikupljanje otpadnih i oborinskih voda. Također, geografski položaj Splita i mediteranska klima ima veliki utjecaj osobito na koncentraciju suspendiranih tvari. Najmanji koeficijent varijacije, oko 4%, za sve lokacije bio je za pH vrijednosti. Vrijednost pH je veoma važna za biološku ravnotežu u prirodnim sustavima (npr. more) jer pH otpadne vode može poremetiti ravnotežu prirodnog sustava. Izmjerene pH vrijednosti su između 6,3 i 8,8, što je u skladu s propisima (pH interval 6-9). Dakle, voda u tom intervalu pH ne bi trebala uzrokovati nikakve biološke probleme na izlazu, imajući u vidu tampon karakteristike morske vode, tako da voda s pH varijacijom od 0,5-1 jedinici kod morske vode (pH=8,2), ne bi uzrokovala značajne promjene.

Iz rezultata u tablicama 9, 10 i 11 vidljiva je bliskost između srednjih i medijan vrijednosti za sve koncentracije onečišćenja osim kod koncentracije deterdženata na Lokaciji 1. Ovaj odnos može se objasniti porijeklom otpadnih voda na toj lokaciji koje su uglavnom iz kućanstva s tog područja te se i njihov sastav pripisuje kućanskim aktivnostima.

Osim već spomenutih akcidentnih slučajeva vezanih za vrijednosti TSS i KPK, primjećuju se konstantno povećane vrijednosti koncentracija o-fosfata iznad MDK koja iznosi 1 mg/L, dok se koncentracije amonijakalnog dušika stalno kreću oko MDK (15 mg/L) i to s tendencijom porasta, što je od izrazite važnosti. Naime, sanitarne karakteristike otpadne vode karakterizirane su, osim mikrobiološkim parametrima, i sadržajem dušika i fosfora čiji su izvori fekalije, ostaci hrane i deterdženti. Spojevi s dušikom (nitriti, nitrati, amonijak i proteini) i fosforom (orto-fosfati, poli-fosfati i organski fosfor), te silikati (suspendirani oblik i orto-silicijeva kiselina) koji se nalaze u sastavu abrazivnih sredstava i deterdženata, najvažniji su nutrijenti u rastu i reprodukciji organizama u površinskim vodama. Važnost kontrole emisije ovih nutrijenata, naročito fosfata, proizlazi iz činjenice da njihova prevelika količina može prouzrokovati pojavu eutrofikacije i cvjetanja algi. Otvorena mora se ne mogu ozbiljnije preopteretiti fosfatom jer je koncentracija Ca^{2+} iona u moru velika, što dovodi do taloženja fosfata. Inače, more ima izražen prihvatni kapacitet otpadnih voda, zbog sposobnosti autopurifikacije, spomenutog taloženja fosfata i redukcije indikatora fekalnog onečišćenja. U odnosu na slatke vode, prednost se ne daje u slučaju smanjenog otapanja kisika zbog povećane koncentracije soli, pa kontrolom emisije tvari koje stvaraju neravnotežu u sustavu moramo paziti da sposobnost autopurifikacije ne bude iscrpljena.

Provedena osnovna statistička analiza dala nam je osnovne smjernice o karakterizaciji pokazatelja onečišćenja komunalnih otpadnih voda i dobiveni rezultati ukazali su na važnost promatranja pojedinih parametara za zadani sustav. S obzirom da mnoge metode kao što su faktorska analiza i analiza glavnih komponenata koje će biti prikazane u slijedećem poglavlju zahtijevaju varijable u skladu s normalnom raspodjelom provedena je nadalje analiza normalnosti raspodjele varijabli. Prije multidimenzionalne kemometrijske analize, normalnost distribucije svih varijabli ispitana je analizom histograma i određivanjem indeksa zakrivljenosti i spljoštenosti primjenom Shapiro-o-Wilk statističkog testa⁸². Provedena je analiza krivulja normalne razdiobe za svaki pokazatelj te su određeni koeficijenti spljoštenosti i zakrivljenosti pojedinih krivulja. Rezultati ovih analiza prikazani su na slikama 19, 20 i 21, te na slikama 22, 23 i 24. Sa slika je vidljivo da gotovo polovica parametara odstupa od normalne razdiobe s jako izraženim koeficijentima spljoštenosti i zakrivljenosti krivulja. Na svim lokacijama distribucija šest varijabli bila je daleko od normalne i šest varijabli unutar normalne distribucije. Izvorni podaci su pokazali da su pH,

KPK, BPK₅, N-NH₄⁺, N-NO₃⁻ i P_{uk} bili uglavnom normalno distribuirani, dok su ostali parametri, TSS, Cl⁻, SO₄²⁻, O-P, N-NO₂⁻ i koncentracija deterdženta, bili pozitivno iskrivljeni, s koeficijentima spljoštenosti značajno većim od nule (95%). Nakon logaritamske transformacije tih parametara, sve vrijednosti zakrivljenosti i spljoštenosti značajno su smanjene. (Slike 22, 23 i 24). Ovaj postupak prilagodbe podataka kao i postupak normalizacije podataka koji je proveden kod kemometrijskih analiza uobičajen je u znanstvenim istraživanjima, a posebice kod kemometrijskih analiza za sustave otpadnih i pitkih voda^{61,62,83}.

Analiza pokazatelja onečišćenja u komunalnim otpadnim vodama i primijenjena deskriptivne statističke analize dali su podatke o kvaliteti otpadnih voda. To su bili neki zaključci za opterećenje Jadranskog mora, u prvom redu Bračkog kanala kao recipijenta otpadnih voda iz najvećeg grada na hrvatskoj strani Jadrana. Posljedice tog zagađenja bile su vezane za hidrodinamičke uvjete koji utječu na vrijeme zadržavanja i razgradnju onečišćivača u otpadnoj vodi. Svi pokazatelji zagađenja mjereni su kontinuirano i rezultat tih mjerenja složeni su u matricu podataka koja se sastoji od velikog broja fizikalno-kemijskih parametara koje je često teško interpretirati i izvući smislene zaključke na temelju promatranja pojedinog pokazatelja, te je neophodno dovesti u vezu pojedine pokazatelje onečišćenja i vidjeti njihov utjecaj na pojedinim lokacijama. Stoga je nadalje provedena multivarijantna analiza pokazatelja onečišćenja kako bi se pokazala prostorna i vremenska raspodijeljenost pokazatelja onečišćenja.

5.2. Prostorna i vremenska klasifikacija pokazatelja onečišćenja komunalnih otpadnih voda grada Splita

Kemometrijska analiza provedena je na osnovi zaključaka osnovne statističke analize te su u analizu uzeti normalizirani podaci 6 pokazatelja onečišćenja kod kojih je utvrđena normalna razdioba. Analiza je izvedena za usporedbu kompozicijskih obrazaca između analiziranih uzoraka i identificiranja čimbenika koji utječu na svakog od njih. Sve informacije o šest pokazatelja onečišćenja na tri lokacije ispusta mogu biti predstavljene u smanjenom prostoru i objašnjene s dvije izračunate varijable (komponente). Temeljem činjenice da je prosječna vlastita vrijednost samodjeljivih podataka jedan, važnim se smatraju samo vrijednosti veće od jedan. Položaj varijabli u faktorskom planu od 2 faktora za analizu glavnih komponenata pokazuje da varijable KPK, BPK₅ i P_{uk} pružaju slične

informacije o onečišćenju otpadnih voda ako uzmemo u obzir sve lokacije (slika 28). To se može objasniti zajedničkim prolaskom opterećenja organskih i mineralnih onečišćenja duž kolektora. Daljnje onečišćenje na bazi komponente dušika (varijable N-NO_3^- i N-NH_4^+) pruža slične informacije također na svim lokacijama..

U provedenoj faktorskoj analizi vidljiva je raspodjela varijabli (pokazatelja onečišćenja u faktorskom planu 1. i 2. faktora. Rezultati tih analiza za pojedine lokacije prikazani su na slikama 25, 26 i 27. Pozitivna vrijednosti faktora 1 i faktora 2 pripadaju pokazateljima onečišćenja iskazanim kao KPK, BPK_5 , N-NH_4^+ , te ukupni P, dok pH ima negativnu vrijednost faktora 1 te pozitivnu vrijednost faktora 2, a dušik izražen ako NO_3^- ima pozitivnu vrijednost faktora 1 te negativnu vrijednost faktora 2. Kod Lokacija 2 i 3 položaj varijabli prema faktorima je grupiran tako da su pokazatelji onečišćenja iskazani kao KPK i BPK_5 u zajedničkom kvadrantu, pokazatelji onečišćenja vezani za N komponente i P komponentu također zajedno, a pH parametar je izdvojen zasebno.

Klaster analiza je primijenjena pri otkrivanju prostorne i vremenske sličnosti za grupiranje lokacija i godina na temelju promatranih pokazatelja onečišćenja. U dosadašnjoj znanstvenoj literaturi upravo je klaster analiza prepoznata kao najprikladnija tehnika svrstavanja promatranih jedinica (lokacije, godine) u grupe sličnih obilježja.

Rezultati ove analize pomoći će u utvrđivanju sličnosti i razlika kanalizacijskih ispusta na osnovi karakteristika otpadnih voda odnosno njihovih pokazatelja onečišćenja, kako bi ih grupirali za predloženo postrojenje za obradu otpadnih voda.

Prostorna klaster analiza rezultirala je dendrogramom s jednom grupom s Lokacijama 2 i 3 pri $(D_{\text{link}}/D_{\text{max}}) \times 100 < 45$ (slika 29.). Dendrogram prikazuje da se sve mjerne lokacije mogu općenito podijeliti u dva glavna klastera (grupe). Klaster I je formiran od Lokacija 2 i 3, a klaster II od Lokacije 1. Klasifikacija između klastera I i II pokazala je značajne varijacije jer su mjesta u ovim klasterima imala slične osobine, prirodnu pozadinu i imala su utjecaj sličnih izvora otpadnih voda. Istu tehniku koristili su i drugi znanstvenici u svojim radovima kakao bi potvrdili sličnosti i razlike među pojedinim promatranim lokacijama bilo za analizu izvorskih ili otpadnih voda^{84,85}. Ovu klasifikaciju možemo objasniti porijeklom otpadnih voda te tako Lokacije 2 i 3 prikupljaju kućanske otpadne vode, industrijske otpadne vode, a dijelom i oborinske vode dakle vode mješovitog tipa. Na Lokaciji 1 uglavnom se prikupljaju otpadne vode iz kućanstava (oko 60%) i oborinske vode iz starog dijela grada s visokom gustoćom naseljenosti i bez utjecaja industrijskih otpadnih

voda. S obzirom da je zadaća ovih kemometrijskih analiza bila definirati vremensku raspodjelu pokazatelja onečišćenja za pojedine lokacije provedena je i klaster analiza po godinama. Ova karakterizacije također je od velike važnosti pri odabiru tehnologije za nadogradnju sustava pročišćavanja. Pravilnim definiranjem kretanja pokazatelja onečišćenja kroz nekoliko godina dolazi se do spoznaja o varijaciji pojedinih pokazatelja u sastavu otpadne vode. Sastav i varijacije koncentracija pokazatelja onečišćenja ulazne otpadne vode ključni su za proces pročišćavanja posebice za biološke procese obrade otpadne vode u kojima količina supstrata definira uspješnost procesa. Rezultati ove analize prikazani su na slikama 30, 31, i 32. Na svim lokacija pokazala se razlika u periodima 2006. i 2007. u odnosu na period 2008. i 2009. Kao razlike u ovim promatranim periodima mogu se načelno navesti klimatske promjene, ali bi za njihovo definiranje trebalo provesti analizu koristeći podatke o oborinama i prosječnim temperaturama. Nadalje razlike se mogu objasniti preko socioloških i ekonomskih pokazatelja iako bi za potpunu potvrdu ovih navoda trebalo provesti i dodatne analize. Ipak možemo reći da su na vremensku raspodjelu pokazatelja onečišćenja vjerojatnije utjecali porast broja stanovnika u odnosu na prve dvije godine, smanjena gospodarska aktivnost posljednje dvije godine, a svakako uz ovo možemo dodati i stabilizaciju sustava primarne obrade otpadne vode. U svakom slučaju ovi rezultati vrijedan su pokazatelj za pravilno definiranje količine i opterećenja otpadnih voda prilikom projektiranja uređaja za obradu. Dobiveni rezultati pokazuju i objašnjavaju sažete informacije o sličnostima i različitostima pojedinih lokacija, identifikaciju pojedinih pokazatelja onečišćenja odgovornih za prostorne varijacije, skrivene faktore objašnjavajući strukturu baze podataka.

Ovo istraživanje predstavlja nužnost i korisnost multivarijantne statističke tehnike za vrednovanje i interpretaciju velikih složenih skupova podataka dajući bolje informacije o kakvoći vode i oblikovanju nadzora s ciljem učinkovitog upravljanja vodenim resursima. Sigurno odlaganje komunalnih i industrijskih otpadnih voda bitan je uvjet Zakona o zaštiti okoliša, koji uspostavlja najveće dopuštene razine različitih zagađivača ispuštenih u prirodni recipijent. Pri izboru odgovarajućeg procesa obrade, odnosno optimalne izvedbe postrojenja, te održavanje stabilnih uvjeta rada na postrojenju za pročišćavanje otpadnih voda (UPOV), potrebne su detaljne godišnje informacije o izvorima, sastavu i razinama onečišćenja u otpadnim vodama. Sustavno praćenje stanja okoliša odnosno pokazatelja onečišćenja, važno je za utvrđivanje kvalitete komunalnih otpadnih voda, prije ispuštanja u

prirodni recipijent. Također, statistička analiza pokazatelja onečišćenja pruža vrijedne informacije koje se mogu koristiti u on-line praćenju kvalitete vode koja dopijeva u prirodni recipijent.

5.3. Viševerijantni linearni modeli pokazatelja onečišćenja komunalnih otpadnih voda grada Splita

Kao osnova za izradu multivarijabilnih linearnih modela poslužila je korelacijska matrica pokazatelja onečišćenja po pojedinim lokacijama za ukupni promatrani period. Dobivene korelacijske matrice prikazane su u tablicama 12 – 14. Analiza četverogodišnjih praćenja vrijednosti pokazatelja onečišćenja otpadne vode provedena u računalnim sustavu STATISTICA 10 utvrdila je postojanje korelacije, točnije pozitivnog trenda između TSS i BPK₅, te između KPK i BPK₅, na svim lokacijama. Ovisnost koncentracije klorida i pH vrijednosti opisana je koeficijentima korelacije čije su vrijednosti negativne za sve lokacije, dok između vrijednosti koncentracija klorida i sulfata postoji izražen pozitivan trend. Nadalje možemo izdvojiti negativne korelacije za koncentracije sulfata i amonijakalnog dušika s KPK i BPK₅ vrijednostima na Lokaciji 3. Na osnovi ovih rezultata daljnja multivarijabilna analiza odnosno izrada modela kojom bi se predviđela razina onečišćenja pojedinih pokazatelja, provedena je za vrijednosti KPK i BPK₅ kao zavisnih varijabli u procesu, dok je broj nezavisnih varijabli mijenjan prema rezultatima korelacijske matrice. Broj nezavisnih varijabli smanjivan je na osnovi dobivene pogreške modela te je tako kao zadovoljavajući modeli odabrani modeli s 9 nezavisnih varijabli. Dobiveni rezultati moraju se promatrati s odgovarajućom razinom sumnje, budući da su analize provedene s razinom signifikantnosti $p < 0,05$. Složena priroda procesa i njegova osjetljivost, odnosno podložnost raznim utjecajima, potvrđeni su rezultatima analiza navedenim u ovom radu. Naime, u svim su modelima kao "prediktori" uključeni različiti parametri onečišćenja.

5.3.1. Viševerijantni linearni model (MLR)

Ovaj linearni model izrađen je pomoću metode viševerijantne linearne regresije (MLR) s razinom signifikantnosti $p \leq 0,05$, a broj nezavisnih varijabli uključenih u model određen je njihovim postupnim isključivanjem iz modela prema prethodnom teorijskom znanju, na temelju ranije provedenih analiza i na temelju rezultata korelacijske matrice. Kao odgovarajući model odabran je model s 9 nezavisnih varijabli i rezultati slaganja modela s

eksperimentalno određenim vrijednostima KPK za sve tri lokacije prikazani su na slikama 33, 37, 41, a za eksperimentalno određene vrijednosti BPK₅ na slikama 35, 39, 43. Regresijski koeficijenti tako izrađenih modela iznose $R^2=0,306 - 0,448$, što pokazuje nedovoljno slaganje izrađenog modela s eksperimentalnim podacima. Rezultati modela pokazuju složenu prirodu pokazatelja onečišćenja i potrebu za korištenjem naprednijih tehnika modeliranja za točniji opis pokazatelja onečišćenja komunalnih otpadnih voda grada Splita.

5.3.2. Model lokalne linearne regresije (PLR)

S obzirom da rezultati prethodnog modela nisu polučili dobre rezultate provedena je izrada složenijeg linearnog modela. Izrađen je model lokalne linearne regresije (PLR) s 9 nezavisnih varijabli za KPK i BPK₅ pokazatelje onečišćenja kao zavisnih varijabli. Kao odgovarajući model odabran je model s 9 nezavisnih varijabli i rezultati slaganja modela s eksperimentalno određenim vrijednostima KPK za sve tri lokacije prikazani su na slikama 34, 38, 42, a za eksperimentalno određene vrijednosti BPK₅ na slikama 36, 40, 44. Regresijski koeficijenti tako izrađenih modela iznose $R^2=0,534 - 0,683$, što pokazuje bolje slaganje izrađenog modela u odnosu na MLR model. Iako je PLR model dao bolje rezultate za opis pokazatelja onečišćenja još uvijek nije dovoljno dobar za opis ovakvog složenog i nelinearnog sustava.

Dakle, vidljivo je da se pokazatelji onečišćenja uvelike mijenjaju, a s tim dakle i uspješnost primarnog procesa obrade, mijenja ovisno o velikom broju čimbenika, čiji utjecaj na proces, kako je i utvrđeno, nije podjednak. Sve to čini vođenje ovog procesa prilično nesigurnim. Međutim, izrađeni modeli, svaki na svoj način i sa svojim stupnjem uspješnosti, mogu se primijeniti za opisivanje ovog procesa te predviđanje njegovog ponašanja u različitim uvjetima. I u ostalim znanstvenim istraživanjima dobiveni su slični rezultati kod opisa procesa s ovim linearnim modelima⁶⁰. Usporedbom regresijskih koeficijenata modela vidljivo je da su složeniji modeli uspješniji u tome, čime je opet potvrđena nelinearna priroda procesa i njegova dinamičnost. U ovom radu za razvijene modele dobivene su prosječne pogreške kod višelinearnog regresijskog modela od oko 90 mg O₂/L, a prosječna pogreška po modelu lokalne linearne regresije za oko 40 mg O₂/L. Ovo nas navodi na zaključak da bi kod opisa ovako nelinearnih sustava trebalo uporabiti složenije tehnike

modeliranja kao što su metoda neuronskih mreža ili metoda neizrazite logike koje su uglavnom u znanstvenoj literaturi koriste za opis ovih sustava.^{74,75,76,86,87}

5.4. Određivanje indeksa kvalitete komunalnih otpadnih voda grada Splita primjenom neizrazite logike

Određivanje indeksa kvalitete voda predmet je brojnih istraživanja danas i provodi se primjenom različitih tehnika i postupaka računanja. Uglavnom se istraživanja provode na pitkim vodama, ali moguće ga je primijeniti i na otpadne vode. Propisi o razinama onečišćenja komunalnih otpadnih voda za puštanje u prirodne recipijente uglavnom su sastavljeni od razreda kojima pripadaju pojedini pokazatelji onečišćenja odnosno njihovih maksimalno dopuštenih koncentracija. Ova klasifikacijska tehnika može uzrokovati nepravilan pristup podacima posebice u slučajevima gdje je parametar blizu ili daleko od granice koja ima istu važnost za vrednovanje koncentracije. Nadalje svaki parametar kvalitete, odnosno pokazatelj onečišćenja može pripadati jednom od razreda te svi parametri ne mogu biti uključeni u jedan razred. Ako se gleda ukupna kvaliteta otpadne vode ona po nekom kriteriju za ispuštanje u prirodni recipijent može zadovoljavati a po nekima ne. Ovako utvrđen izbor kvalitete uzorkovanja na jednom mjestu može predstavljati problem u određivanje kvalitete vode za pojedinu lokaciju, a time nas odvesti na krivi put prilikom odabira postupka pročišćavanja otpadne vode kao i lokacije smještanja samog uređaja za obradu.. Donošenje odluka kod izrade projekata vezanih za zaštitu okoliša je obično složen zadatak koji karakterizira kompromis između ekoloških, društveno-političkih i ekonomskih utjecaja, Znatno broj istraživanja na području analiza višekriterijskih odlučivanja doveo je do izrade dostupnih praktičnih metoda za primjenu teorijskog pristupa višekriterijskog problema.

U ovom radu indeks kvalitete komunalne otpadne vode grada Splita određen je primjenom neizrazite logike sa zadaćom utvrđivanja i detaljnog opisa indeksa kvalitete vode koristeći više kriterija vrednovanja. Na temelju dobivenih rezultata korišten je probablistički pristup za donošenje odluke, kako bi se mogle predložiti moguće lokacije za pročišćavanje otpadnih voda. Kao baza poslužila je prethodno provedena statistička analiza mjerenih parametara na tri lokacije ispusta. Ideja o primjeni tehnike neizrazite logike za integrirani sustav otpadnih voda je izgledna za uključene sustave karakterizirane svojim varijablama, koncentracijskim pragovima, procesom i opisima komponenata. Mogućnost međusobne

korelacije sustava putem jednostavnih pravila i neizrazitih skupova čini jedini način za laku i efikasnu kontrolu integriranog sustava. Neizrazita logika može biti promatrana kao jezik koji dopušta prevođenje sofisticiranih izvješća iz prirodnog jezika u matematičku formu. Neizrazita logika može se nositi s vrlo promjenjivim, jezičnim, nejasnim i nesigurnim podacima ili znanjem i stoga, ima sposobnost kako bi se omogućio logički, pouzdan i transparentan tok informacija iz prikupljenih podataka za korištenje podataka u primjenama za okoliš.

Skup pravila za klasifikaciju kvalitete komunalne vode napravljen je prema prikupljenom skupu značajki i karakteriziran je kao: vrlo dobar, dobar, korektan i loš. Hijerarhijska struktura za klasifikaciju vode sačinjena je na temelju određenih pravila prikazanih na slici 45. Kemijski status vode je ocijenjen kao prva hijerarhijska razina u znanstvenoj bazi. Drugu hijerarhijsku strukturu karakteriziraju u našem slučaju kemijski i fizikalni status vode s ciljem određivanja ocjene kvalitete vode. Slična struktura za klasifikaciju kvalitete vode opisana je u ranijim publikacijama⁸². Na temelju Pravilnika o graničnim vrijednostima opasnih i drugih tvari u otpadnim vodama utemeljen je *popriličan broj neizrazitih pravila* kao npr.: **Ako** je pH „vrlo dobar“ i suspendirana tvar „dobra“ i BPK₅ ili KPK „dobar“ i ukupni N ili ukupni P „dobar“ **onda je status vode „dobar“**.

Stupanj pripadnosti svakog klasifikacijskog pravila ukazuje na vrijednost pripadnosti kod klasifikacije. Veći stupanj pripadnosti, veća je i mogućnost da je voda razvrstana u određenu klasu. Pravila su provedena koristeći prethodno znanje o procesu i rezultate prethodno provedenih statističkih analiza prema godišnjim dobima (Tablice 15 - 26) i prosječne godišnje rezultate za 2006. i 2007. godinu za sve tri lokacije (Tablica 27) kako za hijerarhijsku strukturu tako i za neizrazito opisivanje kvalitete vode. Optimalno prihvatljiva strategija je obično ona za koju je stupanj tvrdnje maksimalan. Eksperimentalni podatci praćeni tijekom dvije navedene godine pokazuju da su najveće prosječne vrijednosti uglavnom zabilježene na Lokaciji 3 (Duilovo). Gotovo sve zabilježene vrijednosti osim pH su iznad vrijednosti propisanih pravilnikom, što bi na prvi pogled upućivalo na zaključak da voda takve kvalitete nije pogodna za ispuštanje u prirodni recipijent i da je potrebna naknadna obrada. Dakle, za dobivanje indeksa kvalitete vode, potrebno je uzeti u obzir sve izmjerene parametre i način njihova dobivanja. Promatrani skupovi podataka i ograničenja ne bi bili izraziti, već kao neizraziti skupovi. Jedan od načina izbjegavanja poteškoća u nesigurnosti upravljanje u ocjeni kvalitete vode je uvođenje mjera sigurnosti ili stupanja

opreza prije primjene jedne od vrijednosti za standarde kvalitete komunalne otpadne vode kao i tehnike koje su korištene od strane drugih ispitivača iz području zaštite okoliša⁸⁸.

Modeliranjem nesigurnosti u našoj znanstvenoj percepciji i postavljenjem neizrazitih skupova/neizrazitih brojeva i nesigurnosti kod dobivenih podataka o parametrima koji utječu na kvalitetu ovih voda, u slijedećem koraku smo uobličili (normalizirali) u neizraziti broj. Konstrukcija broja ili fuzzy skupova za stručnu percepciju modeliranja u klasifikaciji svakog parametra u jezičnim izrazima kao što su: vrlo dobra, dobar, korektan i loš dopušta upućivanje na sve potrebne vrijednosti parametara koja će biti opisani. Dobivene podatke za određene parametre izrazili smo koristeći neizrazitu logiku preko stupnja pripadnosti. Da bi što točnije odredili stupanj vjerojatnosti za kvalitetu vode, funkciju Gaussove krivulje smo dobili uz pomoć interaktivnog programskog jezika MATLAB namijenjenog matričkim izračunavanjima.

Kvaliteta vode za koju je stupanj pripadnosti najveći razmatrana je kao reprezent uzorka kvalitete vode. Rezultati svakog pojedinačnog parametra za ispitivano područje prikazani su u slijedećim tablicama.

Iz tablice 28 je vidljivo da je najveći stupanj pripadnosti kvalitete vode «**vrlo dobar**» respektirajući pH i najveći stupanj pripadnosti kvalitete vode respektirajući suspendiranu tvar. Međutim, ako na isti način razmatramo i ostale parametre navedene u tablici može se kazati da je ukupna kvaliteta vode na Lokaciji 1 «**dobra**».

Analizirajući rezultate iz tablica 29 i 30 uočava se da je kvaliteta vode «**vrlo dobra**» s najvećim stupnjem pripadnosti uzimajući u obzir pH odnosno kvaliteta vode «**loša**» respektirajući suspendiranu tvar i konačno ukupna kvaliteta vode na navedene dvije lokacije je jezično rečeno «**korektna**».

Prema slici 45 u kojoj je opisana hijerarhijska struktura kvalitete vode prema fuzzy pravilu i na kojoj su prikazani jezični opisi kvalitete vode, izrađena je ukupna kvaliteta vode (Tablica 31) prema izračunatim stupnjevima pripadnosti iz Gaussovih krivulja dobivenih MATLAB programskim jezikom za sve tri ispitivane lokacije. Iz tablice 31 je vidljivo da je kvaliteta vode „**dobra**“ s najvećim stupnjem pripadnosti 0,476 za **Lokaciju 1** (2006. g.) odnosno najvećim stupnjevima pripadnosti te 0,981 i 0,351 za **Lokacije 2 i 3** što ukazuje da je ukupna kvaliteta otpadne vode „**korektan**“.

Uspoređujući eksperimentalno dobivene podatke s podacima opisanim primjenom neizrazite logike uočava se da ono što je eksperimentalno utvrđeno kao loše, jezični opis

pokazuje da je „korektno“ ili čak „dobro“. Iz čega je vidljivo da je prvotno ocjenjena kvalitete vode koja se ispušta u prirodni recipijent kao izrazito loša zapravo korektna. Slične studije opisane u ranijim publikacijama, a koje se odnose na primjenu neizrazite logike u okolišnim sustavima ukazuju na iste ili slične zaključke.⁸⁴

Dakle, možemo zaključiti da je kvaliteta komunalnih otpadnih voda koje se nakon primarne ispuštaju na tri lokacije u Jadransko more, opisana koristeći neizrazitu logiku kao mekši oblik računanja. Korišteni su parametri kvalitete vode koji su dobiveni koristeći neizrazitu logiku na tri lokacije, a u svrhu donošenje odluke u pogledu unapređenja postupaka obrade otpadnih voda. Definirane se funkcije pripadnosti parametara kvalitete i utemeljena neizrazita pravila te je korišten MATLAB paket kao fuzzy alat. Indeks kvalitete komunalne vode određuje kvalitetu vode u jezičnim izrazima budući da je neizrazita logika temeljena na pristupu kojem se prepisuje sigurna vrijednost prema različitim jezičnim izrazima. Uzorak vode može biti klasificiran kao „vrlo dobar“, „dobar“, „korektan“ i „loš“, ali s različitim stupnjevima pripadnosti. Glavni razlog za primjenu pristupa fuzzy modeliranja u polju odlučivanja o podržavanju upravljanja vodom prema ovim aplikacijama je sposobnost da integrira znanje, koje je uglavnom strukturirano pomoću jezičnih izraza. Ovaj opis razine onečišćenja otpadnih voda, koje uglavnom potiču iz domaćih industrijskih djelatnosti na širem području Splita kao i njihove sezonske varijacije, može biti od pomoći pri odabiru vrste postupka i predloženog dizajna. To može pružiti bolju prezentaciju dinamičkog sustava i otvoriti novi model za mjerenje kvalitete otpadnih komunalnih voda za specifične ciljeve.

Možemo zaključiti da indeks kvalitete vode definira kvalitetu vode u jezičnim oblicima budući da je neizrazita logika temeljena na pristupu kojem se pripisuje sigurna vrijednost prema različitim jezičnim oblicima. Uzorak vode može biti klasificiran kao vrlo dobar, dobar, korektan i loš, ali sa različitim stupnjevima pripadnosti. Prilične nesigurnosti su uvučene u postupak definiranja kvalitete vode za specifične upotrebe. Skup prikupljenih podataka također pruža mnogo nesigurnosti. Stoga, novi pristup upotrebljava neizrazitu logiku kao mekanu tehniku računanja koja je korištena u ovoj studiji. To može pružiti bolje predstavljanje dinamičkog sustava i može otvoriti novi model za mjerenje kvalitete komunalnih voda za specifične ciljeve.

6. ZAKLJUČCI

Zaključci ovog rada mogu se sumirati prema slijedećim točkama:

- Rezultati monitoringa pokazatelja onečišćenja komunalne otpadne vode grada Splita te njihova karakterizacija predstavljaju važan čimbenik u zaštiti mora kao prirodnog recipijenta, posebice na područjima gdje je turizam glavni gospodarski čimbenik.
- Korištenje osnovnih i naprednih statističkih metoda u obradi rezultata monitoringa pokazatelja onečišćenja uvelike pomaže u razumijevanju samog sustava kod preliminarnih studija koje imaju za cilj optimiziranje i/ili unaprjeđenje vođenja procesa pročišćavanja.
- Provedena osnovna statistička analiza mjerenih parametara pokazatelja onečišćenja komunalnih otpadnih voda grada Splita koji se ulijevaju u more Bračkog kanala pokazala je izrazitu varijabilnost odnosno nestalnost sastava koji je posljedica nehomogenosti uzoraka kao i geografskog položaja te klimatskih obilježja područja grada Splita.
- Prostorna i vremenska raspodjeljenost pokazatelja onečišćenja za razdoblje od 2006. do 2009. godine na tri lokacije dobivena je uz pomoć napredne statističke analize (FA, PCA, CA). Lokacije 2 i 3 mogu se svrstati u jednu skupinu dok je Lokacija 1 izdvojena zasebno. Vremenska raspodjeljenost pokazuje sličnosti u periodu 2006.-2007. i 2008.-2009. za sve lokacije. Pravilnim definiranjem kretanja pokazatelja onečišćenja kroz nekoliko godina dolazi se do spoznaja o varijaciji pojedinih pokazatelja u sastavu otpadne vode. Sastav i varijacije koncentracija pokazatelja onečišćenja ulazne otpadne vode ključni su za proces pročišćavanja posebice za biološke procese obrade otpadne vode u kojima količina supstrata definira uspješnost procesa.
- Na osnovi provedenih multivarijantnih analiza te korelacijskih matrica pokazatelja onečišćenja na pojedinoj lokaciji razvijena su dva empirijska modela za predviđanje vrijednosti KPK i BPK₅ s devet nezavisnih varijabli: viševarijantni linearni regresijski model (MLR) i djelomični linearni regresijski model (PLR).
- Dobivene prosječne pogreške za oba modela koje iznose oko 90 mg O₂/L za MLR model, a oko 40 mg O₂/L za PLR model ukazuju na nelinearnost sustava koju je potrebno opisati složenijim nelinearnim modelima, ali usprkos tome i PLR model može prezentirati kompleksnost i dinamiku ovog sustava s prihvatljivim uspjehom.

- Indeks kvalitete komunalne otpadne vode grada Splita određen je primjenom neizrazite logike sa zadaćom utvrđivanja i detaljnog opisa indeksa kvalitete vode koristeći više kriterija vrednovanja.
- Prema pravilima neizrazite logike (fuzzy logic) te prema prikupljenom skupu značajki ukupnu kvaliteta vode je definirana kao: vrlo dobra, dobra, korektna i loša, ali s različitim stupnjevima pripadnosti.
- Temeljem izračunatih stupnjeva pripadnosti kvaliteta vode je "**dobra**" s najvećim stupnjem pripadnosti 0,476 za Lokaciju 1 odnosno 0,981 i 0,351 za Lokacije 2 i 3 što ukazuje da je ukupna kvaliteta vode "**korektna**".
- Ovakav opis razine onečišćenja otpadne vode, od strane kućanstava i industrije sa šireg područja grada Splita kao i njihovih sezonskih varijacija, može biti zahvalan u odabiru tipa i oblika obrade otpadnih voda. Nadalje, može pružiti bolje postavljanje dinamičkog sustava i može otvoriti novi model za mjerenje kvalitete komunalnih voda za specifične ciljeve.

7. LITERATURA

1. S. Čvrljak: Zaštita okoliša i regionalni razvoj, iskustva i perspektive, Sigurnost **52**, Zagreb, (2010) 99-101.
2. M. Črnjar, K. Črnjar: Menadžment održivog razvoja, Glosa, Opatija, 2009.
3. Zakon o zaštiti prirode, Narodne novine br. 70/2005, 139/2008 i 57/2011.
4. Zakon o zaštiti okoliša, Narodne novine br. 110 (2007).
5. Zaštita okoliša, Minivodič za poslovnu zajednicu, Ministarstvo zaštite okoliša, prostornog uređenja i graditeljstva, 2009.
6. *European Commission*: Information on the 6th Environmental Action Programme: <http://europa.eu.int/scadplus/leg/en/lvb/l28027.htm> (17.09.2012.).
7. D. Šimleša: Ekološki otisak – kako je razvoj zgazio održivost, TIM press d.o.o., Zagreb, 2010.
8. R. Carson: Silent spring, First Mariner Books, New York, 2002.
9. S. Tišma, S. Maleković: Zaštita okoliša i regionalni razvoj, Institut za međunarodne odnose, Zagreb, 2010.
10. Zakon o vodama, Narodne novine br. 153 (2009).
11. I. Bremere, G. Čosić-Flajsig, J. Ignjatović, , Upravljanje vodama na lokalnoj razini, Regionalni centar zaštite okoliša Zagreb, 2010.
12. D. Biondić, Z. Ivaniš, Pregled stanja i smjernice razvoja odvodnje i pročišćavanja komunalnih otpadnih voda u RH, Hrvatske vode, Zagreb, 2011.
13. Pravilnik o graničnim vrijednostima opasnih i drugih tvari u otpadnim vodama, Narodne novine br. 94 (2008).
14. V. Johanides, S. Divjak, Z. Duvnjak, S. Grba, V. Marić, S. Matošić: Industrijska mikrobiologija, Interna skripta, PBF, Zagreb, 1984.
15. G. Tchobanoglous, Wastewater Engineering: Treatment, Disposal, Reuse, McGraw-Hill Inc., Metcalf and Eddy, New York, (1991) 394-453.
16. D. Dujlović, Osnovne značajke otpadnih i oborinskih voda grada Splita, diplomski rad, Građevinsko-arhitektonski fakultet, Split, 2004.
17. B. Tušar: Pročišćavanje otpadnih voda. Kigen d.o.o., Zagreb, 2009.
18. D. Gao, S. Wang, Y. Peng, H. Liang: Temperature effects on DO and ORP in the wastewater treatment, Huan Jing Ke Xue, **24**, (2003.) 9-63.

19. Huber Technology, Mechanical Wastewater Screening, <http://www.huber.de> (11.08.2012.)
20. *H.S. Peavy, D.R. Rowe, G. Tchobanoglous*, Environmental Engineering, McGraw-Hill, New York, (1985) 212-222.
21. *M.F. Dignoc, P. Ginestet, D. Rybacky, A. Bruched, A. Vrban, P. Scribe*, Fate of wastewater organic pollution during activated sludge treatment, Natural of residual organic matter. *Water Res.* **34** (2000) 4185-4194.
22. *M.I.D. Chuehtai, K. Ahmed*, Biological treatment of Liquid effluents, Biological Degradation of Wastes, Elsevier Applied Science, London, (1991) 47-84.
23. *R. Junkis, K. Denny, T. Eckoff*, The Activated Sludge Process: Fundamentals of operation, Ann Arbor Science, Weston, (1983) 24-38.
24. *M.C.M. Van Loosdrecht, M.S.M. Jetten*, 819989 microbiological conversation in nitrogen removal, *Water Sci Technol.*, **38** (1989) 1-7.
25. *E.B. Pike, C.R. Curds*, The microbial ecology of activated sludge process, Microbial Aspects of Pollution, Symposium series No 1, Academic Press, London, (1971) 123-147.
26. *M. Hense, P. Harremoes, J. Jansen, E. Arvin*, Wastewater Treatment, Springer-verlag, Berlin, (1991) 125-148.
27. *A. Abelovich*, Transformations of ammonia and environmental impact of nitrifying Bacteria. *Biodegradation* **3** (1992) 255-264.
28. *E. Bock, H.P. Koops, H. Harms*, Cell Biology of Nitrifiers, In J. I. Prosser (ed.), Nitrification, Washington, D.C. **28** (1986) 17-38.
29. *J.C. Germon*, Denitrification in Nitrogen Cycle. NATO Conference Series 1, Ecology Plenum Press, New York, (1985) 425-478.
30. *R.B. Gauntlett, D.G. Craft*, Biological removal of nitrate from river water, *Water Res. Centre*, (1979) 85-90.
31. *M.H. Gerardi*: Wastewater Bacteria, John Wiley and Sons, New York, 2006.
32. *A. Carucci, D. Dionisi, M. Majone, E. Rolle, P. Smurra*, Aerobic storage by activated sludge on real wastewater, *Water Res.*, **35**, (2001) 3833-3844.
33. *M. Henze*, Principles, modelling and design, Biological wastewater treatment, **14**, (2008) 361-365
34. *G.H. Kristensen, P.E. Jorgensen, M. Henze*, Characterization of functional microorganism groups and substrate in activated sludge and wastewater by AUR, NUR

- and OUR, Water Sci. Tech. **25**, (1992) 43-57.
35. *J.B. Busby, J.F. Adrews*, Water Pollution Control Federation, J. Water P. C., **47**, (1975) 1055-1065.
36. *T. Ohtsuki, T. Kawazoe and T. Masui*, Intelligent Control System Based on Blackboard Concept for wastewater Treatment Processes Water Sci. Technol. **37**, (1998) 77-85.
37. *M. Čurlin*, Modeliranje hidrodinamike i kinetike procesa obrade otpadnih voda u membranskom bioreaktoru disertacija, Sveučilište u Zagrebu, Prehrambeno-biotehnološki fakultet, 2008.
38. *N. Endelhardt, W. Firk, W. Warnken*, Integration of membrane filtration into the activated sludge process in municipal wastewater treatment, Water Sci. Technol. **38**, (1998) 429-436.
39. *W. Fucas Sholz*, Treatment of poil contaminated wastewater in a membrane Bioreactor, Water Res. **14**, (2000) 3621-3629.
40. *T.G. Kueneh, L.A. Robertson*, Trends in microbial Ecology, Spanish Society for Microbiology, (1994) 289-294.
41. Eko-kaštelanski zaljev, <http://www.ekz.hr> (20.08.2012.).
42. *S. Tedeschi*, Zaštita priobalnog mora Splita, Solina, Kaštela i Trogira, Građevinar **55 (8)**, (2003) 443-448.
43. Studija izvedivosti-odvodnja i pročišćavanje otpadnih voda gradova Split-Solin, Southern Water Global, DHV Consultant, IGH P.C. Rijeka, 1996.
44. Podaci o monitoringu kakvoće otpadnih voda u gradu Splitu, Zavod za javno zdravstvo Splitsko-dalmatinske županije, Split, 2006.
45. *N. Ravlić*, Optimizacija projekta prve etape kanalizacijskog sustava Split/Solin, Građevinar **55 (12)**, (2003) 713-722.
46. *R. Žanetić*: Modeliranje održivih kemijsko-tehnoloških sustava, interna skripta, KTF, 2009.
47. *M. Pećina*, Multivarijantna analiza i primjena u oplemenjivanju bilja, doktorska disertacija, Sveučilište u Zagrebu, Agronomski fakultet, 1998.
48. *M.G. Kendall*, A Course in Multivariate Analysis. Charles Griffin & Co., Economica, London, (1957) 183-190.
49. *W.W. Cooley, P.R. Lohnes*, Multivariate Data Analysis, John Wiley & Sons Inc., New York, (1973) 294-295.

50. *A.M. Kshirsagear*, Multivariate Analysis, Marcel Dekker Inc., Classical Methods of Statistics, New York, (1972) 352-370.
51. *A. Gift*, Nonlinear Multivariate Analysis, John Wiley & Sons, Inc., Cross Section and Experimental Data Analysis, New York, (1990) 11-74.
52. *S. Sharma*, Applied Multivariate Techniques, John Wiley & Sons, Inc., Advances in Dynamics, Instrumental and Control, New York, (1996) 297-325.
53. *B.G. Tabachnick, L.S. Fidell*, Using Multivariate Statistics, 2d ed. Harper Collins, New York, (1989) 708-811.
54. *R.R. Velinova, B.K. Koumanova*, Statistical modeling of wastewater quality: The case of micro-electronics industry, Water Res., **29 (11)**, (1995) 2541-2547.
55. *B.S. Everitt, S. Landau, M. Leese*: Cluster analysis, John Wiley and sons, New Jersey, 2009.
56. *K. Kim*, Face Recognition using Principle Component Analysis
Signal Processing Letters, IEEE 9 (2001) 40-42
57. *W. Lin, Y. Qian, X. Li*, Nonlinear dynamic principal component analysis for online process monitoring and diagnosis, Comp. Chem. Eng., **24**, (2000) 423-429.
58. *K.P. Oliveiira-Esquerre, M.Mori and R.E. Bruns*, Simulation of an industrial wastewater treatment plant using artificial neural networks and principal components analysis, Brazilian Journal of Chemical Engineering, **19**, (2002) 365-370.
59. *SAS Institute, Inc.*, SAS/STAT® User's Guide, Version 6, Fourth Edition, **1** (943pp) & **2** (846 pp), Cary, N.C., 1989.
60. *M. Čurlin, A. Bevetek, Z. Ležajić, B. Deverić-Meštrović, Ž. Kurtanjek*, Modeliranje procesa biološke obrade otpadne vode na komunalnom uređaju grada Velika Gorica, Kemija u industriji **57** (2008) 59-67.
61. *R.K. Tomita, S.W. Park, A.Z. Sotomayor*, Analysis of activated sludge process using multivariate statistical tools – a PCA approach, Chem. Eng. **90**, (2002) 283-290.
62. *A. Quali, C. Azri, K. Medhioub, A. Ghrabi*, Descriptive and multivariate analysis of the physico-chemical and biological parameters of Sfax wastewater treatment plant, Desalination, **245**, (2009) 496-505.
63. *H. Melcer*, Methods for Wastewater Characterization in Activated Sludge Modeling,

- Report No. 99-WWF-3, Water Environment Research Foundation (WERF), Alexandria, VA (USA), 2003.
64. *M. Henze, C.P.L. Grady, W Gujer, G.V.R. Marais and T. Matsuo*, Activated Sludge Model No. 1, IAWPRC Scientific and Technical Report No 1. IAWPRC, London, 1987.
65. *S. Grieu, A. Traore, M. Polit, J. Colprim*: Prediction of parameters characterizing the state of a pollution removal biologic process. *Eng. Appl. of AI* **18** (2005) 559-573
66. *K.P. Oliveira-Esquerre, H. Narita, N. Yamato, N. Funamizu and Y. Watanabe*, Modeling of conventional MBR for wastewater treatment, 21st Center of Excellence Program Publication, Hokkaido University, 2005.
67. *G. Reichl*, Wastewater – a library for modeling and simulation of wastewater treatment plants in modelica, 3rd International Modelica Conference. Linköping (2003) pp. 171-176.
68. *K.V. Gernaey et al.*, Wastewater treatment plant influent disturbance models, WWT Mod, 2004, 283-287.
69. *K.M. Lee, N. Park, H. Song*, Can a robot be perceived as a developing creature?, *Hum. Commun. Res.*, **31** (2005) 538-563
70. *F. Camilleri and R. Katebi*, Fuzzy logic control of integrated wastewater systems, 16th IFAC world congress, Prague, July 4-8, 2005.
71. *Y. Icaga*, Fuzzy evaluation of water quality classification, *Ecolog. Indic.*, **7**, (2007) 710-718.
72. *L.A. Zadeh*, Toward a perception-based theory of probabilistic reasoning with imprecise probabilities, *Elsevier* **105**, (2002) 233-264.
73. *A. Astel*, Chemometrics based on fuzzy logic principles in environmental studies, *Talanta* **72**, (2007) 1-12.
74. *A. Punal, E. Roca, J.M. Lema*, Rule-based diagnosis and supervision of pilot scale wastewater treatment plant using fuzzy logic techniques *Water Res.* **22**, (2002) 11-20.
75. *E. Murnleitner, T.M. Becker, A. Deglado*, State detection and control of overloads in the anaerobic wastewater treatment using fuzzy logic *Water Sci. Technol.* **37**, (2002) 77.
76. *T.J.J. Kalker, C.P. Van Goor, P.J. Roeleved, M.F. Ruland and R. Babuška*, Fuzzy control of aeration in an activated sludge wastewater treatment plant: design, simulation *Water Sci. Technol.* **39**, (1999) 71.

77. *B. Fisher*, Fuzzy environmental decision-making: applications to air pollution, *Atmos. Environ.* **37**, (2004) 1865-1877.
78. *A. Salski*, Fuzzy knowledge-based models in ecological research, *Ecol. Model.* **63**, (1992) 103-112.
79. *D. Dunea, M. Oprea*, A Fuzzy Logic Based System for Heavy Metals Loaded Wastewater Monitoring, Proceedings of the 4th WSEAS International Conference on Computational Intelligence, Bucharest, 2010.
80. Standard methods for the examination of water and wastewater, American Public Health Association (APHA), Washington, 1996.
81. *R. Nisbet, J. Elder, G. Miner*: Handbook of statistical analysis and data mining Applications, Elsevier, London, (2009) 153-155.
82. *A.W. Deshpande and D.V. Raje*, Fuzzy logic applications to environment management systems: Case studies, Fourth European Congress on Intelligent Techniques and Soft Computing-EUFIT 1996.
83. *N.V. Kumar, S. Matthew and G. Swaminatham*, Fuzzy information processing for assessment of groundwater quality, *Int. J. Soft Comput.*, **4**, (2009) 1-9.
84. *V. Adrianssens, W. Ocampo-Duque, N. Nezam, L.A. Zadeh*, Towards a Perception-Based Theory of Probabilistic Reasoning-Abstract, Conference of North American fuzzy information processing society, Bannf, Canada, 2000.
85. APHA, Standard methods for the examination of water and wastewater, 18th American Public Health Association, Washington, D.C. 1992.
86. *R. Isermann, S. Ernst and O. Nells*, Identification with dynamic neural networks-architectures, comparisons, applications, IFAC Symposium on System Identification. Fukuoka, Japan (1997) 947-972.
87. *J.H. Tay, X. Zhang*, A fast prediction neural fuzzy model for high-rate anaerobic wastewater treatment systems, *Water Res.* **34**, (2000) 2849-2860.
88. *K.P. Singh, A. Malik, S. Simba*, *Anal. Chim. Acta* **538** (2005) 355-374.

ŽIVOTOPIS

Mladen Perišić je rođen 12. travnja 1962. godine u Splitu gdje je završio osnovnu i srednju školu. Također u Splitu je 1981. godine upisao Kemijsko-tehnološki fakultet koji završava početkom 1986. godine te se iste godine i zapošljava u poduzeću „Brodosplit“ gdje je odradio pripravnički staž od jedne godine. Nakon toga u periodu 1991.-1992. g. radi kao tajnik mjesne zajednice „Sućidar“, a o 1992.-1995. g. obnaša funkciju predstojnika Ureda za obranu Split. Od 1995.-1999. g. bio je ravnatelj Ustanove za zapošljavanje i rehabilitaciju invalida „DES“ u Splitu, a nakon toga u periodu 1999.-2001. g. obnašao dužnost direktora podružnice „AKD zaštita“ za Dalmaciju. U vremenu od 2001.-2002. je bio direktor poduzeća „Prerada d.o.o.“ u Splitu, a od siječnja 2005. g. pa do danas zaposlen je u Splitsko-dalmatinskoj županiji gdje trenutno radi na mjestu savjetnika za regionalni razvoj i europske integracije u Uredu Župana. Poslijediplomski doktorski studij „Kemijsko inženjerstvo u razvoju materijala i zaštiti okoliša“ upisao je šk. godine 2008./2009.

Predsjednik je Gradskog društva Crveni križ u Splitu.

Oženjen je i otac dviju kćerki.

Do sada je objavio 2 znanstvena rada:

1. M. Bralić, **M. Perišić**, M. Čurlin, M. Bugarić, M. Buzuk, and S. Brinić, Application of fuzzy logic to determine the quality of urban wastewater in Split, Croatia, Fresenius Environmental Bulletin **21** (7) (2012) 1712-1720.
2. **M. Perišić**, M. Čurlin, M. Bralić, M. Buzuk, Ljubica Šimac-Peraica, Multivariate analysis of pollution indicator of municipal wastewater in Split area, The Holistic Approach to Environment **2** (3) (2012) 121-131.

Sudjelovao na 3 međunarodna znanstvena skupa:

1. **M. Perišić**, M. Čurlin, M. Bralić, Lj. Šimac-Peraica, Multivariate Linear Regression Model of Pollution Indicators of Municipal Wastewater Wider Area of Split // International Scientific and Professional Conference; 13th Ružička Days / Šubarić, Drago (ur.), Osijek: Faculty of Food Technology/HDKI, 2010. 117.
2. **M. Perišić**, M. Čurlin, M. Bralić, Lj. Šimac-Peraica, MULTIVARIATE STATISTICAL METHODS FOR CHARACTERIZATION OF POLLUTION INDICATORS OF MUNICIPAL WASTEWATER IN SPLIT // Book of abstract 3th International Symposium on Environmental management toward sustainable technologies / Natalija

engineering and technology, 2011. 95.

3. **M. Perišić**, M. Čurlin, M. Bralić, Lj. Šimac-Peraica, Spatial and Temporal Clasification of pollution Indicators of Municipal Wastewater in Split // International Scientific and Professional Conference; 14th Ružička Days / Jukić, Ante (ur.), Osijek Faculty of Food Technology/HDKI, 2012. 120.

Također je bio sudionik i jednog domaćeg skupa:

1. **M. Perišić**, M. Čurlin, M. Bralić, Lj. Šimac-Peraica, S. Brinić, M. Buzuk, Utjecaj temperature i pH na spektrofotometrijsko određivanje fosfata u otpadnim vodama // Knjiga sažetaka / Vesna Tomašić, Karolina Maduna Valkaj (ur.), Zagreb: HDKI/Kemija u industriji, 2011. 154.